

ISSN 2713-3192
DOI 10.15622/ia.2024.23.1
<http://ia.spcras.ru>

ТОМ 23 № 1

**ИНФОРМАТИКА
И АВТОМАТИЗАЦИЯ**

**INFORMATICS
AND AUTOMATION**



СПб ФИЦ РАН

**Санкт-Петербург
2024**



INFORMATICS AND AUTOMATION

Volume 23 № 1, 2024

Scientific and educational journal primarily specialized in computer science, automation, robotics, applied mathematics, interdisciplinary research

Founded in 2002

Founder and Publisher

St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS)

Editor-in-Chief

R. M. Yusupov, Prof., Dr. Sci., Corr. Member of RAS, St. Petersburg, Russia

Editorial Council

A. A. Ashimov	Prof., Dr. Sci., Academician of the National Academy of Sciences of the Republic of Kazakhstan, Almaty, Kazakhstan
I. A. Kalyaev	Prof., Dr. Sci., Academician of RAS, Taganrog, Russia
Yu. A. Merkuryev	Prof., Dr. Sci., Academician of the Latvian Academy of Sciences, Riga, Latvia
A. I. Rudskoi	Prof., Dr. Sci., Academician of RAS, St. Petersburg, Russia
V. Sgurev	Prof., Dr. Sci., Academician of the Bulgarian Academy of Sciences, Sofia, Bulgaria
B. Ya. Sovetov	Prof., Dr. Sci., Academician of RAE, St. Petersburg, Russia
V. A. Soyfer	Prof., Dr. Sci., Academician of RAS, Samara, Russia

Editorial Board

O. Yu. Gusikhin	Ph. D., Dearborn, USA
V. Delic	Prof., Dr. Sci., Novi Sad, Serbia
A. Dolgui	Prof., Dr. Sci., St. Etienne, France
M. N. Favorskaya	Prof., Dr. Sci., Krasnoyarsk, Russia
M. Zelezny	Assoc. Prof., Ph.D., Plzen, Czech Republic
H. Kaya	Assoc. Prof., Ph.D., Utrecht, Netherlands
A. A. Karpov	Assoc. Prof., Dr. Sci., St. Petersburg, Russia
S. V. Kuleshov	Dr. Sci., St. Petersburg, Russia
A. D. Khomonenko	Prof., Dr. Sci., St. Petersburg, Russia
D. A. Ivanov	Prof., Dr. Habil., Berlin, Germany
K. P. Markov	Assoc. Prof., Ph.D., Aizu, Japan
R. V. Meshcheryakov	Prof., Dr. Sci., Moscow, Russia
N. A. Moldovian	Prof., Dr. Sci., St. Petersburg, Russia
V. V. Nikulin	Prof., Ph.D., New York, United States
V. Yu. Osipov	Prof., Dr. Sci., St. Petersburg, Russia
V. K. Pshikhopov	Prof., Dr. Sci., Taganrog, Russia
A. L. Ronzhin	Prof., Dr. Sci., Deputy Editor-in-Chief, St. Petersburg, Russia
H. Samani	Assoc. Prof., Ph.D., Plymouth, UK
A. V. Smirnov	Prof., Dr. Sci., St. Petersburg, Russia
B. V. Sokolov	Prof., Dr. Sci., St. Petersburg, Russia
L. V. Utkin	Prof., Dr. Sci., St. Petersburg, Russia
L. B. Sheremetov	Assoc. Prof., Dr. Sci., Mexico, Mexico

Editor: A.S. Lopotova

Interpreter: Ya.N. Berezina

Art editor: N.A. Dormidontova

Editorial office address

SPC RAS, 39 litera A , 14-th line V.O., St. Petersburg, 199178, Russia

e-mail: ia@spcras.ru, web: <http://ia.spcras.ru>

The journal is indexed in Scopus

The journal is published under the scientific-methodological supervision of Department for Nanotechnologies and Information Technologies of the Russian Academy of Sciences

© St. Petersburg Federal Research Center of the Russian Academy of Sciences, 2024

ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

Том 23 № 1, 2024

Научный, научно-образовательный журнал с базовой специализацией
в области информатики, автоматизации, робототехники, прикладной математики
и междисциплинарных исследований.

Журнал основан в 2002 году

Учредитель и издатель

Федеральное государственное бюджетное учреждение науки
«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук»
(СПб ФИЦ РАН)

Главный редактор

Р. М. Юсупов, чл.-корр. РАН, д-р техн. наук, проф., Санкт-Петербург, РФ

Редакционный совет

А. А. Ашимов	академик Национальной академии наук Республики Казахстан, д-р техн. наук, проф., Алматы, Казахстан
И. А. Каляев	академик РАН, д-р техн. наук, проф., Таганрог, РФ
Ю. А. Меркурьев	академик Латвийской академии наук, д-р, проф., Рига, Латвия
А. И. Рудской	академик РАН, д-р техн. наук, проф., Санкт-Петербург, РФ
В. Сгурев	академик Болгарской академии наук, д-р техн. наук, проф., София, Болгария
Б. Я. Советов	академик РАО, д-р техн. наук, проф., Санкт-Петербург, РФ
В. А. Соيفер	академик РАН, д-р техн. наук, проф., Самара, РФ

Редакционная коллегия

О. Ю. Гусихин	д-р наук, Диаборн, США
В. Делич	д-р техн. наук, проф., Нови-Сад, Сербия
А. Б. Долгий	д-р наук, проф. Сент-Этьен, Франция
М. Железны	д-р наук, доцент, Пльзень, Чешская республика
Д. А. Иванов	д-р экон. наук, проф., Берлин, Германия
Х. Каия	д-р наук, доцент, Утрехт, Нидерланды
А. А. Карпов	д-р техн. наук, доцент, Санкт-Петербург, РФ
С. В. Кулешов	д-р техн. наук, Санкт-Петербург, РФ
К. П. Марков	д-р наук, доцент, Аizu, Япония
Р. В. Мещеряков	д-р техн. наук, проф., Москва, РФ
Н. А. Молдовян	д-р техн. наук, проф., Санкт-Петербург, РФ
В. В. Никулин	д-р наук, проф., Нью-Йорк, США
В. Ю. Осипов	д-р техн. наук, проф., Санкт-Петербург, РФ
В. Х. Пшихопов	д-р техн. наук, проф., Таганрог, РФ
А. Л. Ронжин	д-р техн. наук, проф., зам. главного редактора, Санкт-Петербург, РФ
Х. Самани	д-р наук, доцент, Плимут, Соединённое Королевство
А. В. Смирнов	д-р техн. наук, проф., Санкт-Петербург, РФ
Б. В. Соколов	д-р техн. наук, проф., Санкт-Петербург, РФ
Л. В. Уткин	д-р техн. наук, проф., Санкт-Петербург, РФ
М. Н. Фаворская	д-р техн. наук, проф., Красноярск, РФ
А. Д. Хомоненко	д-р техн. наук, проф., Санкт-Петербург, РФ
Л. Б. Шереметов	д-р техн. наук, Мехико, Мексика

Выпускающий редактор: А.С. Лопотова

Переводчик: Я.Н. Березина

Художественный редактор: Н.А. Дормидонтова

Адрес редакции

14-я линия В.О., д. 39, лит. А, г. Санкт-Петербург, 199178, Россия

e-mail: ia@spcras.ru, сайт: <http://ia.spcras.ru>

Журнал индексируется в международной базе данных Scopus

Журнал входит в «Перечень ведущих рецензируемых научных журналов и изданий, в которых должны быть опубликованы основные научные результаты диссертации на соискание ученой степени доктора и кандидата наук»

Журнал выпускается при научно-методическом руководстве Отделения нанотехнологий и информационных технологий Российской академии наук

© Федеральное государственное бюджетное учреждение науки

«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук», 2024
Разрешается воспроизведение в прессе, а также сообщение в эфир или по кабелю опубликованных в составе печатного периодического издания - журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ» статей по текущим экономическим, политическим, социальным и религиозным вопросам с обязательным указанием имени автора статьи и печатного периодического издания журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ»

CONTENTS

Artificial Intelligence, Knowledge and Data Engineering

A. Povolotskaia, A. Karpov ANALYTICAL REVIEW OF METHODS FOR AUTOMATIC ANALYSIS OF EXTRA-LINGUISTIC UNITS IN SPONTANEOUS SPEECH	5
G.J. Naidu, M. Seshashayee SENTIMENT ANALYSIS FRAMEWORK FOR TELUGU TEXT BASED ON NOVEL CONTRIVED PASSIVE AGGRESSIVE WITH FUZZY WEIGHTING CLASSIFIER (CPSC-FWC)	39
S. Davydenko, E. Kostyuchenko, S. Novikov EVALUATION OF THE INFORMATIVENESS OF FEATURES IN DATASETS FOR CONTINUOUS VERIFICATION	65
N.V. Hung, T.Q. Loi, N.H. Binh, N.T.T. Nga, T.T. Huong, D.L. Luu BUILDING AN ONLINE LEARNING MODEL THROUGH A DANCE RECOGNITION VIDEO BASED ON DEEP LEARNING	101
A. Alsabry, M. Algabri ITERATIVE TUNING OF TREE-ENSEMBLE-BASED MODELS' PARAMETERS USING BAYESIAN OPTIMIZATION FOR BREAST CANCER PREDICTION	129
D. Solovjev COMPETENCE COEFFICIENTS CALCULATION METHOD OF PARTICIPANTS IN GROUP DECISION-MAKING FOR SELECTING THE BEST ALTERNATIVE WITH THE MULTIVARIATE OF THE RESULT	169
Digital Information Telecommunication Technologies	
A. Parshutkin, D. Buchinskiy, Yu. Kopalov MODEL OF SATELLITE COMMUNICATION CHANNEL FUNCTIONING UNDER CONDITIONS OF EPISODIC SYNCHRONIZATION WITH PULSE INTERFERENCE FLOWS	194
O. Lepeshkin, O. Ostroumov, N. Mikhailichenko, A. Permyakov A METHOD FOR ENSURING THE FUNCTIONAL STABILITY OF A COMMUNICATION SYSTEM BY DETECTING CONFLICTS	226
S. Qiushi, H. Yang, O. Petrosian GRAPH ATTENTION NETWORK ENHANCED POWER ALLOCATION FOR WIRELESS CELLULAR SYSTEM	259
B. Swapna, V. Divya LATENCY AWARE INTELLIGENT TASK OFFLOADING SCHEME FOR EDGE-FOG-CLOUD COMPUTING – A REVIEW	284

СОДЕРЖАНИЕ

Искусственный интеллект, инженерия данных и знаний

- А.А. Поволоцкая, А.А. Карпов
АНАЛИТИЧЕСКИЙ ОБЗОР МЕТОДОВ АВТОМАТИЧЕСКОГО АНАЛИЗА
ЭКСТРАЛИНГВИСТИЧЕСКИХ КОМПОНЕНТОВ СПОНТАННОЙ РЕЧИ 5
- Д.Д. Найду, М. Сешашая
СТРУКТУРА АНАЛИЗА ТОНАЛЬНОСТИ ТЕКСТА НА ТЕЛУГУ,
ОСНОВАННАЯ НА НОВОМ ИЗОБРЕТЕННОМ ПАССИВНО-
АГРЕССИВНОМ КЛАССИФИКАТОРЕ С НЕЧЕТКИМ ВЗВЕШИВАНИЕМ 39
(CPSC-FWC)
- С.А. Давыденко, Е.Ю. Костюченко, С.Н. Новиков
ОЦЕНИВАНИЕ ИНФОРМАТИВНОСТИ ПРИЗНАКОВ В НАБОРАХ
ДАННЫХ ДЛЯ ПРОВЕДЕНИЯ ПРОДЛЁННОЙ АУТЕНТИФИКАЦИИ 65
- Н.В. Хунг, Т.К. Лои, Н.Х. Бинь, Н.Т.Т. Нга, Т.Т. Хьонг, Д.Л. Луу
ПОСТРОЕНИЕ МОДЕЛИ ОНЛАЙН-ОБУЧЕНИЯ С ПОМОЩЬЮ ВИДЕО
ПО РАСПОЗНАВАНИЮ ТАНЦЕВ, ОСНОВАННОГО НА ГЛУБОКОМ
ОБУЧЕНИИ 101
- А. Алсабри, М. Альгабри
ИТЕРАТИВНАЯ НАСТРОЙКА ПАРАМЕТРОВ МОДЕЛЕЙ НА ОСНОВЕ
ДРЕВОВИДНЫХ АНСАМБЛЕЙ С ИСПОЛЬЗОВАНИЕМ БАЙЕСОВСКОЙ
ОПТИМИЗАЦИИ ДЛЯ ПРОГНОЗИРОВАНИЯ РАКА МОЛОЧНОЙ
ЖЕЛЕЗЫ 129
- Д.С. Соловьев
МЕТОД РАСЧЕТА КОЭФФИЦИЕНТОВ КОМПЕТЕНТНОСТИ
УЧАСТНИКОВ ГРУППОВОГО ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ ВЫБОРА
НАИЛУЧШЕЙ АЛЬТЕРНАТИВЫ ПРИ МУЛЬТИВАРИАНТНОСТИ
РЕЗУЛЬТАТА 169
- Цифровые информационно-телекоммуникационные технологии**
- А.В. Паршуткин, Д.И. Бучинский, Ю.Н. Копалов
МОДЕЛЬ ФУНКЦИОНИРОВАНИЯ КАНАЛА СПУТНИКОВОЙ СВЯЗИ В
УСЛОВИЯХ ЭПИЗОДИЧЕСКОЙ синхронизации с ПОТОКАМИ
ИМПУЛЬСНЫХ ПОМЕХ 194
- О.М. Лепешкин, О.А. Остроумов, Н.В. Михайличенко, А.С. Пермяков
МЕТОДИКА ОБЕСПЕЧЕНИЯ ФУНКЦИОНАЛЬНОЙ УСТОЙЧИВОСТИ
СИСТЕМЫ СВЯЗИ ЗА СЧЕТ ВЫЯВЛЕНИЯ КОНФЛИКТОВ 226
- С. Цюши, Х. Ян, О.Л. Петросян
СЕТЬ GRAPH ATTENTION РАСШИРЕННОЕ РАСПРЕДЕЛЕНИЕ
МОЩНОСТИ ДЛЯ БЕСПРОВОДНОЙ СОТОВОЙ СИСТЕМЫ 259
- Б. Свапна, В. Дивья
ИНТЕЛЛЕКТУАЛЬНАЯ СХЕМА РАЗГРУЗКИ ЗАДАЧ С УЧЕТОМ
ЗАДЕРЖЕК ДЛЯ ВЫЧИСЛЕНИЙ В EDGE-FOG-CLOUD — ОБЗОР 284

А.А. ПОВОЛОЦКАЯ, А.А. КАРПОВ
**АНАЛИТИЧЕСКИЙ ОБЗОР МЕТОДОВ АВТОМАТИЧЕСКОГО
АНАЛИЗА ЭКСТРАЛИНГВИСТИЧЕСКИХ КОМПОНЕНТОВ
СПОНТАННОЙ РЕЧИ**

Поволоцкая А.А., Карпов А.А. Аналитический обзор методов автоматического анализа экстралингвистических компонентов спонтанной речи.

Аннотация. Точность систем автоматического распознавания спонтанной речи далека от тех, которые демонстрируют системы распознавания подготовленной речи. Обусловлено это тем, что спонтанная речь не характеризуется той плавностью и отсутствием сбоев, что подготовленная. Спонтанная речь варьируется от диктора к диктору: отличное произношение фонем, наличие пауз, речевых сбоев и экстралингвистических компонентов (смех, кашель, чихание, и цыканье при выражении эмоции раздражения и др.) прерывают плавность вербальной речи. Экстралингвистические компоненты очень часто несут важную паралингвистическую информацию, поэтому для систем автоматического распознавания спонтанной речи важно распознавать подобные явления в потоке речи. В данном обзоре проанализированы научные работы, посвященные проблеме автоматического анализа экстралингвистических компонентов спонтанной речи. Рассмотрены и описаны как отдельные методы и подходы по распознаванию экстралингвистических компонентов в потоке речи, так и работы, связанные с многоклассовой классификацией изолированно записанных экстралингвистических компонентов. Наиболее распространенными методами анализа экстралингвистических компонентов являются нейронные сети, такие как глубокие нейронные сети и сети на основе моделей-трансформеров. Приведены основные понятия, относящиеся к термину экстралингвистические компоненты, предложена оригинальная систематизация экстралингвистических компонентов в русском языке, описаны корпуса и базы данных звучащей разговорной речи как на русском, так и на других языках, также приведены наборы данных экстралингвистических компонентов, записанных изолированно. Точность распознавания экстралингвистических компонентов повышается при соблюдении следующих условия работы с речевым сигналом: предобработка аудиосигналов вокализаций показала повышение точности классификации отдельно записанных экстралингвистических компонентов; учет контекста (анализ нескольких фреймов речевого сигнала) и использование фильтров для сглаживания временных рядов после извлечения векторов признаков показали повышение точности при пофреймовом анализе речевого сигнала со спонтанной речью.

Ключевые слова: автоматическое распознавание речи, речевые технологии, машинное обучение, прикладная лингвистика, экстралингвистические компоненты, спонтанная речь, автоматическое распознавание экстралингвистических компонентов.

1. Введение. Поток вербальной речи характеризуется наличием паралингвистических и экстралингвистических средств, которые, формируя речевой портрет человека, способствуют распознаванию его психоэмоционального и физического состояний. Паралингвистические фонационные явления, такие как интонация, мелодика, длина пауз, темп, тембр, громкость речи, часто используются при решении задач

классификации эмоций. В то время как, экстралингвистические средства включают в себя паузы, и различные психоэмоциональные проявления невербального характера (плач, смех, кашель, вздохи/выдохи и др.). Несмотря на достигнутый существенный прогресс в области автоматического распознавания речи (АРР), до сих пор уделяется недостаточно внимания анализу экстралингвистических средств речи. Анализ экстралингвистических средств позволит решить сложные научно-технические вопросы в области АРР, распознавания психоэмоциональных и физических состояний человека, поскольку, подобные невербальные явления могут содержать больше информации, чем вербальное выражения эмоций.

Экстралингвистические средства часто расцениваются, как «зашумление» исходного речевого сигнала или «артефакты», которые, присутствуя в потоке речи, нарушают работу систем АРР или запросно-ответных диалоговых систем [1]. Также, определенную сложность создают явления, воспроизводимые совместно с речью, например, когда человек смеется и пытается одновременно что-то сказать (речевой смех). С другой стороны, на данный момент нет единого мнения и определенного термина, который бы характеризовал экстралингвистические средства, присутствующие в речи человека.

Совершенствование методов анализа экстралингвистических средств позволит применять их в различных областях, которые перечислены ниже.

1) Биометрические технологии: распознавание и верификация диктора [2, 3].

2) Автоматическая расширенная транскрипция [4, 5].

3) Учет экстралингвистических средств при распознавании эмоций в речи [4, 6].

4) Оценка здоровья говорящего: детектирование кашля, как симптом заболевания дыхательных путей или проявления психоэмоционального состояния [7, 8].

5) Усовершенствование устройств для контроля родителями новорожденных или маленьких детей, оставшихся в комнате одни (радио няня), путем классификации детских вокализаций: плач, смех, маргинальный/канонический лепет [9].

6) Совершенствование диалоговых систем и голосовых ассистентов, как при распознавании речи пользователя, так и при составлении ответа системы [10, 11]. Возможность «очеловечить» голосового ассистента и диалоговые системы путем включения экстралингвистических средств в поток речи, синтезируемой системой.

7) Совершенствование человеко-машинного взаимодействия для людей с ограниченными возможностями, т.е. управление мобильными устройствами и компьютерами с помощью определенных команд-звуков, например, щелканье языком – «выбрать элемент», более интенсивный выдох – «отправить сообщение» и т.д. [12].

Данная статья посвящена обзору современных технологий автоматического анализа экстралингвистических средств. В разделе 2 содержатся основные понятия и оригинальная систематизация. В разделе 3 приведен сравнительно-сопоставительный обзор существующих корпусов и наборов данных, на основе которых возможно обучение моделей систем для анализа экстралингвистических средств в спонтанной речи. На основе проведенного обзора предложена методика записи корпуса со спонтанной речью. В разделах 4 и 5 представлен аналитический обзор подходов и методов автоматического анализа экстралингвистических средств как в спонтанной речи (СР), так и распознавание экстралингвистических средств, записанных изолированно. Выводы по проделанной работе оформлены в разделе 6.

2. Основные понятия и систематизация экстралингвистических компонентов. В [13] явления, подобные смеху, кашлю, икоте и др. называются невербальные вокализации (НВ, *nonverbal vocalization*). В [14] подобные краткие, невербальные произнесения, возникающие между эпизодами речи называются вокальные всплески (*vocal bursts*). Одна и та же НВ может представлять реализацию различных явлений. Например, вздох может являться как вегетативным звуком (процесс дыхания), так и быть частью смеха, или быть прагматическим сигналом со значением раздражения, усталости или просьбы обратить внимание.

В [15] предложено деление НВ на четыре следующих уровня:

1) вегетативный уровень – явления, подобные дыханию, чиханию, и другим рефлекторным реакциям, которые могут сигнализировать о состоянии здоровья человека, но и использоваться для распознавания личности говорящего.

2) орфографический уровень – представляет НВ, которые могут быть записана в виде последовательности звуков (фонем) одного языка и быть понятной для носителей этого языка (орфографическая невербальная вокализация).

3) аффективный уровень – аффективные звуки и большинство междометий определяют аффективное и психоэмоциональное состояние человека. Аффективная информация

обычно не присутствует в вегетативных звуках и звуках-заполнителях. Звуки обратной связи (ответные лексемы), однако, иногда могут передавать аффективную информацию.

4) прагматический уровень – представляет выражение некоторых НВ в роли прагматических частиц, которые выполняют функцию управления разговором. Например, звуки обратной связи (ответные лексемы), смех и аффективные звуки могут выполнять функцию поддержания разговора.

В результате проведенного обзора литературы было решено: систематизация экстралингвистических средств и их объединение под общим термином вокализации не представляется возможным, поскольку, в процессе вокализации участвуют голосовые связки. В связи с чем решено разделить экстралингвистические средства на экстралингвистические явления (ЭЯ), т.е. кашель, чихание, цыканье и другие звуки, при воспроизведении которых голосовые связки не принимают участие, и экстралингвистические вокализации (ЭВ), когда голосовые связки вибрируют, и объединить экстралингвистические явления и вокализации под общим термином экстралингвистические компоненты (ЭК) вербальной речи.

На рисунке 1 представлена оригинальная систематизация ЭК для русского языка. Все ЭК можно разделить на: 1) врожденные, 2) приобретенные.



Рис. 1. Систематизация экстралингвистических компонентов в русском языке

1) Врожденные ЭК. Подразделяются на вегетативные (рефлекторные) и протофоны, т.е. звуки, которые закладываются у человека во время внутриутробного развития и формируются во время первых дней жизни:

а. вегетативные (рефлекторные) звуки такие как: вдох-выдох, глотательные звуки, жевательные звуки, одышка (после физической нагрузки), в первую очередь, не являются коммуникативными сигналами и не все находятся под осознанным контролем. Как правило, вегетативные звуки не «изучаются» и не «заучиваются» человеком, а являются естественными физиологическими процессами, контролируемые подсознательно. Также в данную группу входят естественные реакции организма человека на определенные возбудители/раздражители: кашель, икота, зевота, чихание, отрыжка и др. В данную группу также возможно отнести плач и крик (у детей это сигналы дистресса), смех, и другие эмоциональные реакции, провоцируемые внешними и внутренними (психоэмоциональные процессы) стимулами.

б. к вокализациям у младенцев также относятся протофоны (речеподобные звуки), которые могут быть свободными вокализациями – отдельные звуки, квазисогласные, маргинальный и канонический лепет. Воспроизводство протофонов является эндогенным и сигнализирует о психофизиологическом состоянии ребенка на довербальной стадии развития, в то время как крик, смех, плач несут социальную функцию и выражают определенные эмоциональные состояния [16].

2) Приобретенные ЭК. В раннем возрасте звуки дистресса (смех, плач, крик, и др.) являются произвольными и не контролируются ребенком осознанно. По мере взросления, человек овладевает навыками коммуникации, взаимодействуя с другими членами общества, осваивает правила и нормы коммуникации, и «научается» контролировать различные проявления своих эмоций в соответствии с культурными особенностями общества.

а. звуки, артикулируемые с помощью речевого аппарата, можно разделить по активному действующему органу: язык (щелканье, цыканье, др.); губы (причмокивание, свист, др.); зубы (стук, скрипение, др.); звуки, реализуемые посредством мягкого неба, а именно, при его опускании (звуки храпа, хрюканья и др.).

б. вокализованные звуки (или аффективные звуки) могут реализовываться с преобладанием голоса (во время фонации голосовые связки будут сведены, напряжены и находиться в состоянии колебания) в таком случае воспроизводится крик, возгласы,

плач, смех, и др.; так и шума (нет смычки между голосовыми связками и отсутствует колебание) может быть реализовано что-то похожее на кряхтение, шипение, кашель и др.

в. звуки нефонемного характера реализуются во время заполненных пауз хезитации: гласные без цели, плюс потенциальный нейтральный носовой согласный («эм» или «mmm»); гудящие сигналы, («хм», «ага», «угу» и др. – обычно они используются как сигналы обратного ответа, но потенциально используются также для выражения отношения в разговоре); воспроизведение мелодий без текста с использованием одного звука («промычать» или «промурлыкать»).

г. эксплетивные единицы – десемантизированные элементы разговорной речи, которые являются, скорее, формой удержания канала связи, к ним также относятся дискурсивные слова (ДС): «ну», «это», «которое», «типа», «во-о-от», и др.

д. аффективы или междометия не имеют адресата сообщения и являются формой выражения эмоции различной степени лексикализации: «ба!», «ого!», «ой», «тс-с-с-с» и др.

Речь каждого индивида уникальна и может характеризоваться индивидуальными особенностями, как врожденными, так и приобретенными:

а. возможно частое употребление ДС. Что может быть проявлением речевой привычки, заполнителем пауз хезитации, выражением эмоционального состояния или мнения, маркерами членения текста, способом управления вниманием слушающего.

б. наличие синдромов речевых нарушений, которые могут быть как врожденными (наследственные заболевания с умственной отсталостью, характеризующиеся проблемами развития речи: затяжки звуков и/или их частое повторение), и приобретенными, возникающие при органических расстройствах речевого отдела коры головного мозга в результате перенесенных травм, опухолей, инсультов и др.

в. наличие нейродегенеративных болезней: боковой амиотрофический склероз, болезни Альцгеймера и Паркинсона и др., когда наблюдается заметное изменение в порождении речи.

Такую систематизацию можно признать универсальной, поскольку она описывает и объединяет все ЭК по характеристики врожденности-приобретенности и не рассматривает ЭК с точки зрения прагматической составляющей, т.е. мотивированности использования в потоке речи.

3. Базы данных звучащей разговорной речи и отдельно записанных экстралингвистических компонентов. Наиболее часто ЭК встречаются в СР. СР – неподготовленная и экспромтная,

ситуативно обусловленная речевая деятельность, используемая в контексте повседневного неформального общения между собеседниками, которые состоят в неофициальных отношениях, включающая элементы нормированного и ненормированного произношения.

Систематизированные данные обзора корпусов СР представлены в таблицах 1 (русская речь) и 2 (речь на иностранных языках), в которых содержится следующая информация по корпусам: общая длительность звучания в часах (Д); количество дикторов их пол (М – мужчины, Ж – женщины) и возраст (В); методика записи корпуса; уровни разметки: орфографическая расшифровка (О), хезитации и речевые сбои (Х), экстралингвистические компоненты (ЭК), («+» – выполнена полная разметка, «±» – выполнена частичная разметка, «-» – разметка отсутствует); режим доступа.

Таблица 1. Сравнение корпусов спонтанной русской речи

Корпус	Дикторы			Методика записи	Д	Уровни разметки			Доступ
	В	М	Ж			О	Х	ЭК	
САТ [17]	18–52	89	123	чтение и пересказ текста, описание изобр., рассказ на тему	~50	-	-	-	По запросу
ОРД [18]	18–83	69	61	повседневное общение	~5	+	+	+	Закрытый
Корпуса звучащей речи [19]	7–17	59	67	рассказ о сновидениях	~5	+	+	±	По запросу ¹
	19–70	8	9	рассказы сибиряков о жизни					
	20–30	12	28	рассказы из жизни					
CORUSS [20]	16–30	10	10	чтение текста, монолог, диалог	>10	-	+	+	По запросу
	31–45	10	10						
	46–77	10	10						
РМД [21]	18–36	34	62	пересказ фильма – полилог 3 участников	~17	+	+	+	По запросу ²

Проанализированы также корпуса, содержащие речь на других языках. В таблице 2 представлены не только американский (The Buckeye speech corpus [22]) и британский английский (LUCID [23], SSPNet Vocalization Corpus [24]), но и интерферированная речь китайцев: мандаринский, сингапурский и тайванский диалекты китайского (The Wildcat Corpus [25], SpiCE [26]), речь корейцев,

¹ <http://spokencorpora.ru/>

² <https://multidiscourse.ru/main/>

испанцев, турков и дикторов других национальностей (ALLSSTAR [27], The ICSI Meeting Corpus [28]). Также, в таблице 2 приведена информация по корпусам на других языках: китайском [28], венгерском [30], которые часто встречаются в исследованиях по распознаванию СР и ЭК.

Таблица 2. Сравнение корпусов разговорной речи на иностранных языках

Корпус	Дикторы			Методика записи	Д	Уровни разметки			Доступ
	В	М	Ж			О	Х	ЭК	
Английский язык									
Buckeye [22]	18–30	10	10	интервью	~19	+	+	+	Открытый ³
	40–60	10	10						
LUCID [23]	19–29	20	20	поиск отличий на изобр. в парах	~73	+	±	±	Открытый ⁴
SSPNet [24]	18–64	57	63	сравнение ответов на вопросы	~9	+	+	+	По запросу
Wildcat [25]	18–33	20	20	поиск отличий на изобр. в парах	~40	+	+	+	Открытый ⁵
	22–34	36	24						
SpiCE [26]	19–34	10	17	рассказ по ряду изобр., интервью	~10	+	±	±	Открытый ⁶
ALLS-STAR [27]	18–41	86	54	параллельный перевод; история и поиск отличий по изобр.; интервью	~48	+	±	±	Открытый ⁷
The ICSI Meeting Corpus [28]	20–62	40	13	запись полилогов в конференц-зале Международного института компьютерных наук	~72	+	+	+	Открытый ⁸
Китайский язык									
NNIME [29]	19–30	20	22	спонтанные пьесы между двумя актерами	~11	+	+	+	Открытый ⁹
Венгерский язык									
BEA HSLD [30]	20–90	112	168	рассказ и выражение мнения; полилог по теме; пересказ текста	~260	+	+	±	Закрытый

³ <https://buckeyecorpus.osu.edu/>
⁴ <https://valeriehazan.com/wp/index.php/lucid-corpus-london-ucl-clear-speech-in-interaction/>
⁵ https://groups.linguistics.northwestern.edu/speech_comm_group/wildcat/
⁶ <https://borealisdata.ca/dataset.xhtml?persistentId=doi:10.5683/SP2/MJOXP3>
⁷ <https://speechbox.linguistics.northwestern.edu/ALLSSTARcentral/#!/recordings>
⁸ <https://groups.inf.ed.ac.uk/ami/icsi/>
⁹ <https://nnime.ee.nthu.edu.tw/>

Можно выделить несколько основных методик сбора данных со СР: интервью или ответы на вопросы, с которыми диктор не был ознакомлен до проведения записи; рассказ или монолог на определенную тему (чаще всего о пережитом опыте диктора); описание картинок или составление рассказа по ряду изображений; карта или поиск маршрута.

Если для участия в записи разговорной спонтанной речи привлекать пары дикторов (друзей, влюбленных, родителей с детьми, и других людей), которые продолжительное время состоят в близком неформальном контакте, то можно создать более неформальную обстановку в процессе общения в рамках студийной записи, чем если будут приглашены два абсолютно незнакомых человека, которым будет выдано задание.

В качестве методики сбора корпуса со СР предлагается использовать дикторов, состоящий в близком контакте продолжительное время и представлять им игровой формат коммуникации, в которой дикторам не указывается конкретная цель (проложить маршрут на карте, найти отличия и др.), но где необходимо использовать ассоциативное мышление, также, стоит предположить, что, если ограничить количество каналов информации (например, оставить только речевой), то возможно получить более вариативную речь, с большим количеством озвученных ЭК.

Для анализа ЭК в рамках русской СР целесообразно использование следующих корпусов: «CAT» [17], «Корпуса звучащей речи» [19], «CORUSS» [20], поскольку в этих корпусах представлены записи звучащей русской речи, наиболее близкой к спонтанной, также, представлена речь носителей русского языка, в дальнейшем возможна апробация системы анализа ЭК на других языках.

Проведен обзор наборов данных с ЭК, записанными отдельно от речи. Сравнение наборов данных представлено в таблице 3, где содержится информация о продолжительности звучания (количество данных: Ч – часы, Ф – количество фрагментов); список реализованных ЭК и их количество – ЭК (количество); режиме доступа.

Для изучения ЭК и последующего обучения моделей, или отдельных блоков ИНН необходимо использование наборов данных с ЭК, реализованными изолированно: «Multiclass cough sound dataset» [7], «ASVP-ESD» [31], FSD50K (Human Sounds) [34], «VocalSound» [35], поскольку, данные корпуса находятся в открытом доступе и, в общей сложности, имеют широкий спектр реализованных ЭК.

Таблица 3. Наборы данных с экстралингвистическими компонентами

Набор данных	Объем данных		ЭК (количество)	Доступ
	Ч	Ф		
Multiclass cough sound [7]	~1	2944	кашель: бронхиальная астма (787); covid-19 (907); сердечная недостаточность (554); здоровое дыхание (696)	Открытый ¹⁰
ASVP-ESD [31]	~11	3 104	плач (892); смех (772); крик (679)	Открытый ¹¹
H-VB [32]	~37	59 201	вздых; смех; плач; крик; ворчание/хрюканье; стон; тяжелое дыхание; др.	Закрытый ¹²
MAHNOB [33]	~4	1 697	смех (563); речевые высказывания (849); удивление (494); постановочный смех (51); речевой смех (67); другие вокализации (167)	По запросу ¹³
FSD50K (Human Sounds) [34]	~23	20 004	возглас (1368); крик (1246); смех (5696); плач/всхлипывание (1462); вопль/стон (215); вздох (321); завывания (702); ворчание (334); свист (1985); дыхание (834); кашель (871); чихание (1200); внюхивание (205); жевание (829); кусание (366); полоскание (137); отрывка (1302); икота (931); др.	Открытый ¹⁴
VocalSound [35]	~24	21 024	смех; вздох; кашель; прочищение горла; чихание; вдыхание/сопение (все звуки по 3504 фрагментов)	Открытый ¹⁵

Не стоит исключать возможного увеличения наборов данных путем либо накладывания звуковых сигналов с ЭК на вербальную речь, либо осуществлять поиск подобных пересечений в открытых источниках, связано это с тем, что во время речепорождения

¹⁰ http://web.firat.edu.tr/turkertuncer/acute_asthma_cough.rar.

¹¹ <https://www.kaggle.com/datasets/dejolilandry/asvpesdspeech-nonspeech-emotional-utterances>

¹² <https://doi.org/10.5281/zenodo.6320973>

¹³ <https://mahnob-db.eu/laughter/>

¹⁴ <https://zenodo.org/record/4060432>

¹⁵ <https://github.com/YuanGongND/vocalsound>

возможны такие явления как речевой смех, или, когда во время плача/приступа икоты человек пытается что-то произнести.

4. Методы автоматического анализа ЭК, записанных отдельно от речи, в рамках соревнований Affective Vocal Bursts (A-VB'22). Известно не так много исследований, посвященных анализу ЭК в СР. Исследования ведутся либо по анализу одной-двух определенных реализаций ЭК во всем речевом сигнале, либо осуществляется классификация фрагментов ЭК, записанных отдельно от речи.

В 2022 году на международной конференции ACII (Affective Computing + Intelligent Interaction) состоялся семинар в рамках соревнований, посвященных распознаванию аффективных вокальных всплесков (Affective Vocal Bursts, A-VB¹⁶), записанных отдельно от речи [32]: смех, вздох, ворчание и др. В рамках соревнования был представлен большой набор данных Hume-VB¹⁷, описание которого приведено в таблице 3. Весь набор данных (59 201 аудиофрагмент) был поделен на 3 выборки: обучающая, валидационная и тестовая, в каждой по 19 900 аудиофрагментов. Участники представляли работу с описанием метода, где указывали результаты классификации, полученные на тестовом выборке.

Соревнование включало 4 различных задания:

1) *A-VB-High* – *Классификация эмоций*. Участникам предстояло построить модель многоцелевой регрессии для распознавания 10 эмоций, связанных с вокальными всплесками. По результатам экспериментов, участники сообщали среднее значение коэффициента корреляции конкордации (Concordance Correlation Coefficient, CCC) по всем десяти эмоциям.

2) *A-VB-Two* – *Классификация валентности и степени возбуждения эмоции* – регрессионная задача, в которой модель должна определить значения возбуждения и валентности (в соответствии со следующими значениями: 1 – неприятное/подавленное, 5 – нейтральное, 9 – приятное/стимулированное), представленные в циклической модели аффектов. Участники сообщали организаторам среднее значение CCC по двум измерениям.

3) *A-VB-Culture* – *Классификация эмоций с учетом культурной принадлежности диктора* – многоцелевая регрессионная задача. Модель должна распознать интенсивность 40 эмоций (по 10 для каждого языка/культуры), представленного в наборе данных по

¹⁶ <https://www.competitions.hume.ai/avb2022>

¹⁷ <https://zenodo.org/record/6308780>

дикторам из следующих стран: США (английский язык), Китай (мандаринский китайского язык), Южная Африка (английский), Венесуэла (испанский язык). Все участники сообщали среднее значение CCC по всем 40 эмоциям.

4) *A-VB Туре – Классификация типа вокализаций*. Модель классифицирует типы экспрессивного вокального всплеска по 8 классам (вздых, смех, плач, крик, ворчание/хрюканье, стон, тяжелое дыхание, другое). Участники сообщали значение показателя невзвешенного среднего (Unweighted Average Recall, UAR) в качестве показателя точности.

В рамках обзора основной фокус смещен в сторону четвертого задания – *A-VB Туре – Классификация типа вокализаций*, где основной задачей является классификация ЭК (результаты предложенных моделей представлены в таблице 4).

Таблица 4. Сравнение результатов работы методов на соревновании A-VB'22 в задании *Классификация типа вокализаций* (UAR, %)

Работа	Метод классификации	Результат	
		Валидационная выборка	Тестовая выборка
[37]	data2vec-SM	58,40	58,60
[38]	wav2vec 2.0	56,86	56,18
[39]	wav2vec2 – XLSR53	49,89	49,70
[32]	End2You (базовый метод)	41,66	41,72

Ниже приведен обзор методов, представленных в соревновании.

4.1. Базовый метод [32]. В качестве базового метода авторами был выбран инструментарий для мультимодального профилирования с помощью сквозного глубокого обучения End2You. Метод приведен на рисунке 2.

Признаки извлекаются покадрово из необработанного сигнала с помощью нейронной сети Emo-18 CNN, предобученную на наборе данных RECOLA [36]. За ней следуют двуслойная сеть долгой краткосрочной памяти (Long Short-Term Memory, LSTM), которая для последующей классификации использует временные паттерны сигнала. Результаты классификации реализованной базовой модели представлены в таблице 4, на валидационной и тестовой выборках результат составил 41,66% и 41,72% по показателю UAR, соответственно.

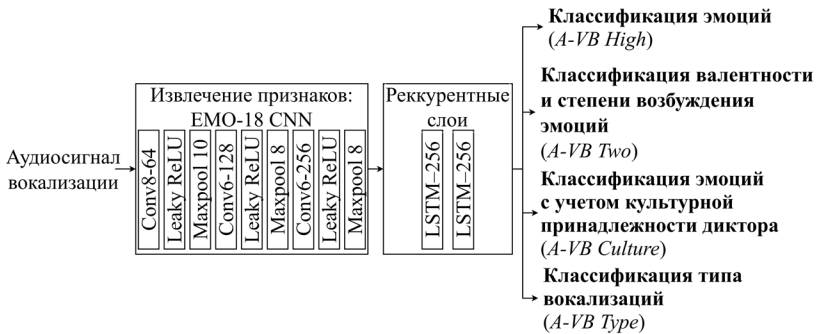


Рис. 2. Схема базового метода в рамках соревнования A-VB'22 [32]

4.2. Метод на основе data2vec-SM [37]. Для классификации ЭК группа авторов использовала предобученную модель data2vec. Схема метода представлена на рисунке 3.




Рис. 3. Схема метода на основе data2vec [37]

Необработанный аудиосигнал подается в предварительно обученную модель data2vec, которая включает блок предобработки. Переменная длина последовательности дополняется нулями до самой длинной последовательности. Из-за маски внимания (attention mask), извлеченные признаки различаются по длине, поэтому они объединяются с помощью операции среднего пулинга (average pooling) и передаются в последующие слои проекции.

Проекционные слои уменьшают размерность выходных данных с помощью функции GELU (Gaussian Error Linear Unit), которая уменьшает размерность до требуемой для конкретной задачи (Классификация типа вокализации = 8).

Для классификации используется функция активации Softmax, функция потерь – перекрестная энтропия (cross-entropy, CE) с

использованием обратно пропорциональных весов классов. Затем значения потерь линейно объединяются через найденные оптимальные веса. Результаты представлены в таблице 4, на валидационной и тестовой выборках результат составил 58,40% и 58,60% по показателю UAR, соответственно.

4.3. Метод на основе wav2vec 2.0 [38]. В основу данного метода легло использование большой предобученной модели с режимом самообучения (self-supervised learning) wav2vec2.0. Особенность архитектуры: признаки, полученные с помощью wav2vec2.0, являются отправной точкой для первой задачи (*Классификация типа вокализаций (A-VB Type)*), затем полученные прогнозы для первого задания объединяются с прогнозами каждой последующей задачи, и используются в качестве входных данных для следующей задачи. Метод представлен на рисунке 4.

В качестве адаптивной стратегии инициализации весов использовался метод Dynamic Weight Averaging (DWA), который является частным случаем Softmax распределения, с помощью которого инициализируются веса λ_k для каждого k -ого класса [39]:

$$\lambda_k(t) = \frac{K \exp\left(\frac{L_k(t-1)}{L_k(t-2)} / T\right)}{\sum_{i=1}^N \exp(w_i(t-1) / T)}, \quad (1)$$

где k – класс из множества классов K в рамках многозадачного обучения; t – индекс итерации; T – «температура» Softmax, которая управляет мягкостью распределения вероятностей в задаче; L – значение потери, N – количество состояний для каждого i -го состояния, где каждое i -ое состояние – класс. Большое значение T приводит к более равномерному распределению между различными задачами. Если значение T достаточно велико, тогда $\lambda_i \approx 1$ и задачи взвешиваются одинаково. Оператор Softmax, который умножается на количество классов K гарантирует, что $\sum_{i=1}^N \lambda_i(t) = K$. В реализации [38] значение потери $L_k(t)$ рассчитывается как среднее значение потери в каждой эпохе за несколько итераций, что позволяет уменьшить неопределенность, возникающую при стохастическом градиентном спуске и случайном выборе обучающих данных. Две первые итерации $t=1$ и 2 в [38] были проинициализированы, как $w_k(t) = 1$.

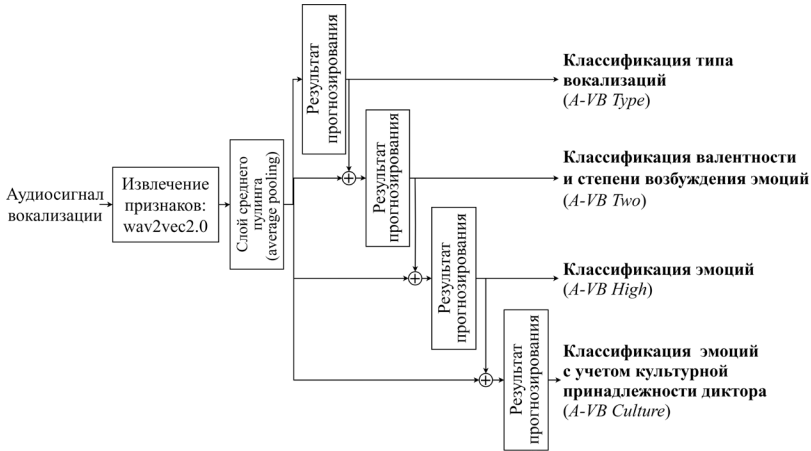


Рис. 4. Схема метода на основе wav2vec 2.0 в рамках соревнования A-VB'22 [38]

Общая сумма потерь становится взвешенной суммой [38]:

$$L_{DWA} = \sum_{k=1}^K \lambda_k(t) L_k, \quad (2)$$

где λ_k – проинициализированные веса на итерации t , L_k – значение функции потерь.

Результаты представлены в таблице 4, на валидационной и тестовой выборках результат составил 56,86% и 56,18% по показателю UAR, соответственно.

4.4. Метод на основе wav2vec2-XLSR53 [40]. Модель wav2vec-XLSR53 представляет базовую конфигурацию трансформера, обученного на трех наборах неразмеченных данных: Multilingual LibriSpeech [41], Common Voice [42], BABEL [43], которая использовалась для извлечения признаков аудиосигнала. Схема модели представлена на рисунке 5.

Последовательность признаков, полученных из аудиосигнала моделью wav2vec-XLSR53, подается на вход сети LSTM. За слоем LSTM следует полносвязный слой (Fully Connected, FC). Использование FC обосновано необходимостью сокращения размерности вложения до значения, соответствующего значению выходного слоя в зависимости от задания, затем слой последнего пулинга (last pooling) [44], т.е. используется последний вектор

признаков из последовательности, и завершает модель функция потерь CCC.

Результаты представлены в таблице 4, на валидационной и тестовой выборках результат составил 49,89% и 49,70% по показателю UAR, соответственно.

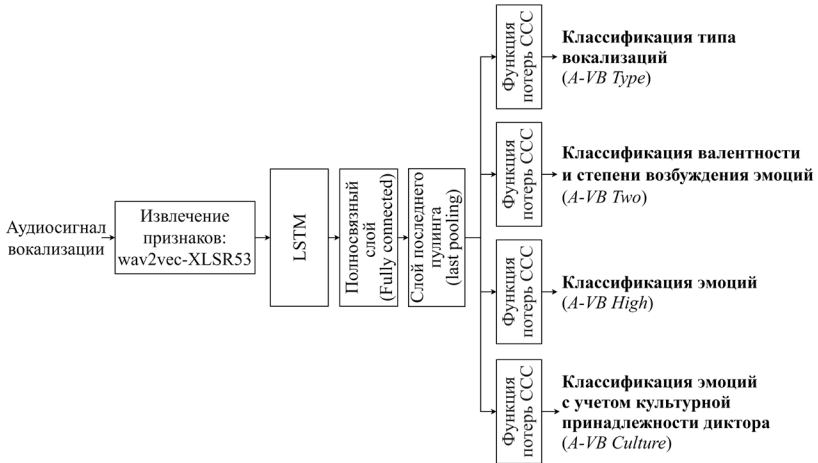


Рис. 5. Схема метода на основе wav2vec-XLSR53 в рамках соревнования A-VB'22 [40]

В рамках соревнования A-VB'22 наилучший результат показала модель data2vec-SM: 58,40% и 58,60% на валидационной и тестовой выборках, соответственно, по показателю UAR. Это единственная модель, где осуществлялась предобработка сигнала перед тем, как передать его в следующие блоки.

Однако, стоит отметить то, что во всех моделях осуществлялось параллельное прогнозирование результатов классификации по всем заданиям соревнования, и лишь метод на основе wav2vec2.0 [38], реализован в виде каскадной структуры, сначала прогнозируется результат для задания *Классификация типа вокализаций*, и затем, основываясь на результатах прогнозирования, осуществляет анализ и классификацию ЭК для каждого последующего задания. Это является правильной стратегией прогнозирования при решении нескольких задач, отличающихся сложностью и прослеживаемой иерархичностью, поскольку лишь на основе выделения общих признаков отдельно взятых ЭК, можно

предсказать более частные, например эмоцию, культурную группу диктора, и др.

Для классификации ЭК во всех методах использовались модели с уже предобученными моделями на корпусах с большим объемом данных, таких как: Multilingual LibriSpeech [41], Common Voice [42], BABEL [43], Libri-Light [45], MSP-Podcast [46], которые включают в себя записи звучащей речи как размеченной, так и неразмеченной. Модель data2vec-SM, используемая в рамках соревнования, не была дообучена после предварительного обучения на корпусе Librispeech ASR [47], с использованием инструмента для измерения скорости работы моделей Libri-Light ASR benchmark [45] для большой версии, поскольку ЭК не являются вербальной речью, а представляют собой сигнал, который состоит из вокализованных эмоций.

5. Методы автоматического анализа ЭК в потоке речи с использованием корпуса SSPNet Vocalization Corpus. Область анализа пауз хезитации и смеха, как экстралингвистических средств, в потоке речи постепенно становится более популярной, поскольку ученые осознают важность употребления подобных сигналов человеком.

Комплексные исследования ЭК в СР осуществлялись на корпусе SSPNet Vocalization Corpus, представленном в рамках соревнования *INTERSPEECH 2013 (Social Signals Sub-Challenge* [48]), в котором были вручную аннотированы два типа ЭВ: смех, заполнитель или заполненные паузы хезитации - “*uhm*”, “*eh*”, “*ah*”, как сигналы удержания речевой инициативы), и «мусорные» кадры (“*garbage*”), которые представляют другие вокализации, такие как речь либо тишину. Корпус состоит из 2763 аудиофрагментов (11 секунд каждый): 1158 фрагментов смеха, 2988 – заполненных пауз хезитации. В рамках соревнования задача состояла в покадровой классификации двух классов событий: смеха и заполненных пауз хезитации. Точность работы метода рассчитывалась с использованием показателя площади под кривой (Area Under Curve, AUC) для каждого явления в отдельности. Поскольку распознавались два типа явлений: смех (L – laughter) и заполненные паузы-хезитации (F – fillers), расчет для двух событий (B – both) определялся невзвешенной средней оценкой площади под кривой (Unweighted Average AUC, UAAUC). Результаты исследований представлены в таблице 5.

Таблица 5. Результаты методов выявления смеха (L), заполненных пауз хезитации (F), совместно для смеха и пауз-хезитации (B)

Работа (год)	Акустические признаки	Классификатор	Результат		
			AUC		UAAUC
			L	F	B
[48] (2013)	Для MFCC 1-12, LE - Δ и Δ^2 значения. Для VP, HNR, F0, ZCR - Δ значения. μ, σ	SVM с линейным ядром	82,9	83,6	—
[50] (2014)	Для MFCC 1-12, LE - Δ и Δ^2 значения. Для VP, HNR, F0, ZCR - Δ значения. μ, σ	Deep BLSTM RNN	—	—	94,0
[52] (2016)	Вероятность вокализации, MFCC 1-12, HNR, F0, ZCR, логарифмическая интенсивность сигнала	DNN и вероятностное кодирование	95,3	90,4	—
[53] (2017)	MFCC	DNN+CMA-ES	94,4	88,0	91,2
	FBANK		95,0	87,7	91,3
	ComParE		96,0	90,1	93,1

5.1. Метод на основе SVM с линейным ядром [48]. В базовом подходе анализ ЭК осуществлялся с помощью метода опорных векторов с линейным ядром (linear kernel Support Vector Machines).

Набор акустических признаков для базового метода: покадрово вычислялись мел-частотные кепстральные коэффициенты (англ. Mel-Frequency Cepstral Coefficients, MFCC) 1-12 и логарифмическая энергия сигнала (logarithmic energy, LE) вместе с их производными первого (Δ) и второго порядка (Δ^2), вероятность вокализации (voicing probability, VP), отношение гармоника/шум (HNR), частота основного тона (F0), число переходов через ноль (ZCR) и их производные первого порядка. Затем для каждого низкоуровневого дескриптора (Low Level Descriptors, LLD) вычисляются среднее арифметическое (μ) и стандартное отклонение (σ) на уровне кадра и восьми соседних кадров (четыре до и четыре после). В результате вычисляется $47 \times 3 = 141$ дескриптор на кадр.

Авторы воспользовались реализацией классификатора из набора инструментов WEKA [49]. Для данной задачи использовался метод опорных векторов с линейным ядром. В качестве алгоритма обучения использовалась последовательная минимальная оптимизация (Sequential Minimal Optimization, SMO), параметр сложности, который позволяет найти компромисс между

максимизацией разделяющей полосы и минимизацией суммарной ошибки, составил $C = 10^{-3}$. Чтобы справиться с несбалансированным распределением классов, использовалась субдискретизация, после использования которой осталось только 5% «мусорных» кадров. Результат покадрового обнаружения смеха и заполненных пауз гезитации представлен в таблице 5, на тестовой выборке метод показал 82,9% и 83,6% по классам «смех» и «заполнитель», соответственно.

5.2. Метод на основе Deep BLSTM RNN [50]. В данной работе представлено использование модели двунаправленной рекуррентной нейронной сети (Reccurent Neural Network, RNN) с долгой краткосрочной памятью (Bidirectional LSTM, BiLSTM), путем наложения комбинации глубокой нейронной сети (Deep Neural Network, DNN) и BiLSTM. Схема метода представлена на рисунке 6.




Рис. 6. Схема метода на основе DNN+BiLSTM [50]

С помощью экстрактора признаков с открытым исходным кодом openSMILE [51], каждые 10 мс при размере кадра 25 мс извлекались следующие низкоуровневые дескрипторы и функционалы: LE, коэффициенты MFCC 1-12, для которых также вычислялись Δ и Δ^2 ; VP, HNR, F0, ZCR и Δ для каждого признака.

Результат покадрового обнаружения смеха и заполнителей представлен в таблице 5, авторами был приведен только совместный показатель UAAUC = 94% по двум классам «смех» и «заполнитель».

5.3. Метод учета контекстных признаков и принятия решения на основе значения вероятности [52]. В работе демонстрируется трехэтапный алгоритм анализа смеха и заполненных пауз гезитации в потоке речи (рисунок 7).

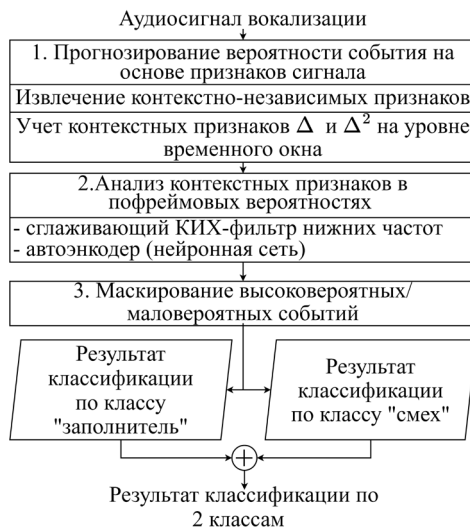


Рис. 7. Схема 3-этапного метода анализа ЭК с учетом контекстных признаков и принятия решения на основе значения вероятности [52]

Этап 1. Прогнозирование вероятности события $E \in \{\text{«смех»}, \text{«заполнитель»}\}$. На этом этапе выполняются следующие действия:

а) Извлечение контекстно-независимых признаков. В данном блоке прогнозирование осуществляется с использованием предобученной DNN с двумя скрытыми слоями, на выходном слое три нейрона (в соответствии с количеством классов: «смех», «заполнитель», «мусор»), каждый с сигмоидной функцией активации прогнозирует значения вероятностей каждого из трех событий. Всего извлекались 17 признаков (таблица 5) из каждого фрейма (вектор признаков для x -го фрейма обозначен как x_n), соответствующее значение вероятности, полученное для события E в пределах фрейма, обозначается $u(n)$). Перед последующим обучением системы была осуществлена z -нормализация каждого вектора признаков для каждого файла. Средние значения и дисперсия признаков для нормализации рассчитывались с учетом всей длительности файла.

б) Учет контекстных признаков. Учет контекстных признаков осуществляется следующим образом: для прогнозирования вероятности события E в x_n -ом фрейме устанавливается длина окна $2M_x + 1$, где значение M_x – количество фреймов до и после x_n -го

фрейма. К каждому из признаков из текущего x_n -го фрейма добавляются значения Δ и Δ^2 , которые извлекаются из соответствующего окна. В результате получается вектор признаков размерностью 17×3 (признак + Δ + Δ^2), затем, на наборе из 51 признака вычисляются μ и σ , и уже на данном наборе признаков реализуется дообучение DNN модели. В результате получается временной ряд $U = (u_1(n), \dots, u_i(N))$.

Этап 2. Учет контекста в вероятностных значениях, полученных на уровне фрейма.

а) КИХ-фильтр низких частот был спроектирован для устранения выбросов во временном ряде U . Для каждого класса из E событий вычисляется сглаженное значение вероятностей $v[n]$ посредством применения сглаживающего КИХ-фильтра низких частот, как показано в формуле [52]:

$$v[n] = \sum_{m=-M}^M a_m u(n+m), \quad (3)$$

где a_m – это коэффициент фильтрации, применяемый к выходным фреймам на расстоянии m от текущего фрейма. Коэффициенты фильтра (a_m) определялись с помощью минимальной среднеквадратической ошибки (MMSE).

б) Вероятностное кодирование. В результате применения сглаживающего КИХ-фильтра низких частот были устранены все нелинейные зависимости. Значения вероятностей $v[n]$ поступают на вход автоэнкодера (нейронная сеть с прямой связью и сигмоидной функцией на единственном выходном нейроне). Задача данной операции, как утверждают авторы, – зафиксировать любую нелинейную контекстную зависимость, которую линейный фильтр не смог отследить. Детальное описание модели автоэнкодера в статье не приведено.

Этап 3. Маскирование высоко- и мало-вероятностных событий на основе правил, основанных на эвристике:

1) маскирование нулями: если существует непрерывное существование значений вероятности $w_E(n)$ ниже порогового значения T_0 , по крайней мере, для заданного числа фреймов K_0 , все такие вероятности маскируются нулем.

2) маскирование единицами: если значения вероятности смежно превышают пороговое значение T_1 , по крайней мере, для числа K_1 фреймов, все такие вероятности маскируются единицей.

Подбор пороговых значений T_0 и T_1 , и значения фреймов K_0 и K_1 осуществлялся на валидационном наборе данных. В [52] значения $T_0 = 0,02$ и $T_1 = 0,98$.

Результат пофреймового обнаружения смеха и пауз хезитации представлен в таблице 5, на тестовой выборке метод показал AUC = 95,3% и 90,4% по классам «смех» и «заполнитель», соответственно.

5.4. Метод на основе DNN и CMA-ES [53]. В данной статье приведен пример использования DNN и фильтра, сглаживающего временные ряды, оптимизация весов которого была проведена на основе метода оптимизации CMA-ES (Covariance Matrix Adaptation Evolution Strategy – эволюционная стратегия адаптации ковариационной матрицы). Метод оптимизации весов фильтра с помощью CMA-ES подробно описан в [54] и имеет сходство с методом главных компонент.

Авторы выделили три группы признаков, описанные ниже, на основе которых проводилось покадровый анализ фрагментов CP:

1) Стандартный: 13 коэффициентов MFCC, их первая и вторая производные.

2) FBANK: 20 значений гребенки мел-частотных фильтров, логарифмическая энергия, значения Δ и Δ^2 .

3) ComParE – *INTERSPEECH 2013 Computational Paralinguistic Challenge*: 13 коэффициентов MFCC, значения Δ и Δ^2 ; VP, HNR, F0, ZCR и Δ для каждого признака. В общей сложности 47 признаков, которые извлекаются с помощью набора программных средств openSMILE [51].

Пофреймовые значения вероятностей были получены с помощью DNN, изначально обученной для получения апостериорной оценки фонемы на уровне фрейма, методом скользящего окна с учетом соседних векторов признаков на уровне фреймов. Подробное описание обучения DNN в статье не приведено.

Полученные значения вероятностей на каждом фрейме агрегируются в локальном окружении из нескольких векторов, число которых было определено на предыдущем этапе. Для фильтра с шириной $2N + 1$ значения весов были определены следующим образом: $(w_{-N}, w_{-N+1}, \dots, w_N) \geq 0$ и $\sum_{i=-N}^N w_i = 1$. Далее для каждого j -го фрейма со значением правдоподобия вычислялось значение агрегирования по формуле [53]:

$$a'_j = \sum_{i=-N}^N w_i a_{j+i}, \quad (4)$$

где w_i – значения весов, которые подбираются с помощью определенного типа фильтра.

В общей сложности были протестированы 4 типа фильтра: константный, треугольный, фильтр на основе DNN, и фильтр на основе CMA-ES. Лучший результат показал фильтр, значения весов которого были подобраны с помощью метода CMA-ES.

Результат покадрового обнаружения смеха и заполнителей представлен в таблице 5, на тестовой выборке метод показал 95,0% и 90,1% по классам «смех» и «заполнитель», соответственно. Результат для совместных событий составил UAAUC = 93,1%.

Наилучший результат UAAUC = 94,0% показала модель на основе комбинации DNN и BiLSTM, однако, в статье не приведены отдельные результаты по классам «смех» и «заполнители», лучшие отдельные результаты показала модель на основе DNN и оптимизатора CMA-ES – 96,0% по классу «смех» и 90,1% по классу «заполнитель».

На основе проведенного обзора литературы можно сделать вывод, что повышение качества анализа ЭК в СР возможно при условии использования фильтров сглаживания временных рядов после выделения высокоуровневых признаков с использованием нейронной сети. Также, стоит отметить, что при анализе ЭК в СР необходимо принимать во внимание признаки не только анализируемого кадра, но и нескольких соседних (т.е. осуществлять анализ контекста), для повышения точности используемого метода. Стоит отметить, что ни в одном из вышеперечисленных подходов не использовались методы предобработки речевого сигнала для последующего извлечения признаков. Материал корпуса SSPNet Vocalization Corpus был записан на мобильное устройство Nokia N900, что могло повлиять на качество записанного речевого материала.

6. Заключение. В данной статье представлен аналитический обзор научных исследований, посвященных анализу ЭК в СР, так и ЭК, записанных отдельно. Рассмотрены лингвистические основы ЭК, приведена оригинальная систематизация. Представлен сравнительно-сопоставительный обзор корпусов со СР и наборы данных с ЭС, записанными отдельно от речи.

На основе проведенного аналитического обзора существующих подходов к анализу ЭК в СР, можно сформулировать следующие

предложения для повышения точности распознавания подобных явлений в СР:

а. При аннотации ЭК в корпусах СР важно размечать фрагменты пересечения речи и ЭК. ЭК могут проявляться не только как отдельные от речи события, но и пересекаться с речью и другими средствами. Есть предположение, что в случае, отсутствия пересечения ЭК с речью точность анализа ЭК в потоке СР будет проходить успешнее, нежели, если речь смешивается с ЭК. И, как следствие, репрезентативное представление пересечений ЭК с речью в корпусах СР позволит повысить точность анализа подобных событий в потоке СР.

б. При исследовании ЭК, которые включают в себя два рефлекторных процесса (вдох и выдох), такие как смех, плач, крик и др., целесообразно учитывать акустические характеристики как вдоха, так и выдоха, поскольку представляют одно цельное событие (смех/плач/крик), а не отдельные друг от друга явления.

в. Первично исследование ЭК в рамках одной культуры, поскольку авторы предполагают межкультурную вариативность в реализациях ЭК. Межкультурное исследование ЭК вторично, поскольку возможны схожие реализации отдельных ЭК в рамках одной языковой группы.

г. В условиях зашумленной обстановки качество выявления и анализа ЭК значительно снижается, вследствие чего необходимо производить предварительную очистку или подавление, отличных от речи шумов, присутствующих в сигнале.

д. Для повышения точности распознавания ЭК в СР необходимо рассматривать более широкий спектр корпусов и баз данных. Для обучения системы необходимо использовать не только записи СР, но и отдельно записанные ЭК, также возможно использование записей людей с дефектами речи и моторно-речевыми нарушениями, тем самым, выборка реализаций ЭК будет более вариативна и станет возможным учет различных особенностей воспроизводства тех или иных ЭК.

е. Для более точного выявления ЭК необходимо либо увеличивать ширину фрейма, либо при анализе текущего фрейма учитывать контекст (3-4 соседних фрейма), связано это с тем, что скорость смены фонем не соответствует скорости возникновения и продолжительности ЭК в потоке речи, следовательно, для фиксирования ЭК либо повторяемости акустических признаков, похожих на ЭК в сигнале методу необходимо захватывать «большой обзор» сигнала для его анализа.

В дальнейшей работе планируется проведение ряда исследований, посвященных изучению акустических характеристик различных ЭК, исследование статистических зависимостей, и анализ ЭК в потоке СР.

1) Планируется провести исследования на наборах данных с ЭК, записанными отдельно от речи: «Multiclass cough sound dataset» [7], «ASVP-ESD» [31], FSD50K (Human Sounds) [34], «VocalSound» [35], для того чтобы подобрать оптимальные модели искусственных нейронных сетей (ИНС), которые позволят повысить точность распознавания ЭК в формате отдельных от речи аудиофрагментов. Планируется осуществить сопоставление и тестирование различных наборов признаков (GeMAPS, eGeMAPS, VoAW, wav2vec, wav2vec2, и др.) на качество распознавания ЭК.

Также, для повышения точности распознавания отдельно записанных ЭК будет необходимо провести аугментацию данных, путем извлечения различных реализаций ЭК из корпусов СР, также возможна запись уникального корпуса СР и отдельно записанных ЭК.

2) Анализ реализаций ЭК в рамках спонтанной русской речи. Исследование будет проводиться на корпусах подобных «САТ» [17], «Корпуса звучащей речи» [19], «CORUSS» [20]. Предполагается исследовать методы предобработки речевого сигнала со СР для последующего выделения векторов признаков из каждого фрейма. В рамках второго этапа планируется изучить влияние ширины фрейма на качество распознавания ЭК в СР.

3) Кросс-культурное исследование ЭК. Исследование возможности применения методов на основе ИНС, разработанных для анализа ЭК в рамках одной культуры (русский язык), для распознавания ЭК в другой (английский язык). В рамках исследования ЭК у англоговорящих дикторов возможно использование следующих корпусов со СР: Buckeye [22], LUCID [23], Wildcat [25], SpiCE [26], ICSI meeting corpus [28].

4) Оформление выводов по произведенной работе и разработка автоматической системы, которая будет осуществлять анализ ЭК различного типа в СР.

Литература

1. Верховданова В.О., Шапранов В.В., Кипяtkова И.С., Карпов А.А. Автоматическое определение вокализованных гезитаций в русской речи // Вопросы языкознания. 2018. № 6. С. 104–118.
2. Ataollahi F., Suarez M.T. Laughter Classification Using 3D Convolutional Neural Networks // Proceedings of the 3rd International Conference on Advances in Artificial Intelligence (ICAAI '19). 2019. pp. 47–51.

3. Судьенкова А.В. Обзор методов извлечения акустических признаков речи в задаче распознавания диктора // Сборник научных трудов НГТУ. 2019. № 3–4. С. 139–164.
4. Hsu J.-H., Su M.-H., Wu C.-H., Chen Y.-H. Speech Emotion Recognition Considering Nonverbal Vocalization in Affective Conversations // IEEE/ACM Transactions on Audio, Speech, and Language Processing. 2021. vol. 29. pp. 1675–1686.
5. Dumpala S.H., Alluri K.N.R.K.R. An Algorithm for Detection of Breath Sounds in Spontaneous Speech with Application to Speaker Recognition. Speech and Computer: 19th International Conference (SPECOM). 2017. pp. 98–108.
6. Huang K.-Y., Wu C.-H., Hong Q.-B., Su M.-H., Chen Y.-H. Speech Emotion Recognition Using Deep Neural Network Considering Verbal and Nonverbal Speech Sounds // International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2019. pp. 5866–5870.
7. Kuluozturk M., Kobat M.A., Barua P.D., Dogan S., Tuncer T., Tan R.S., Ciaccio E.J., Acharya U.R. DKPNet41: Directed knight pattern network-based cough sound classification model for automatic disease diagnosis // Medical engineering and physics. 2022. vol. 110. no. 103870.
8. Lahmiri S., Tadj C., Gargour C., Bekiros S. Deep learning systems for automatic diagnosis of infant cry signals // Chaos, Solitons & Fractals. 2022. vol. 154. no. 111700.
9. Matkoliaie F.S., Tadj C. Machine Learning-Based Cry Diagnostic System for Identifying Septic Newborns // Journal of Voice. 2022. DOI: 10.1016/j.jvoice.2021.12.021.
10. Matsuda T., Arimoto Y. Detection of laughter and screaming using the attention and etc models // Proceedings of INTERSPEECH 2023. pp. 1025–1029. DOI: 10.21437/Interspeech.2023-1412.
11. Ortega D., Meyer S., Schweitzer A., Vu N.T. Modeling Speaker-Listener Interaction for Backchannel Prediction // 13th International Workshop on Spoken Dialogue Systems Technology. 2023. pp. 1–16.
12. Lea C., Huang Z., Jain D., Tooley L., Liaghat Z., Thelapurath S., Findlater L., Bigham J.P. Nonverbal Sound Detection for Disordered Speech // International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2022. pp. 7397–7401.
13. Crystal D. Prosodic Systems and Intonation in English // Cambridge University Press, 1969. 390 p.
14. Simon-Thomas E., Sauter D., Sinicropi-Yao L., Abramson A., Keltner D. Vocal Bursts Communicate Discrete Emotions: Evidence for New Displays. Nature Proceedings. 2007. DOI: 10.1038/npre.2007.1356.1.
15. Trouvain J., Truong K.P. Comparing non-verbal vocalisations in conversational speech corpora. Proceedings of the 4th International Workshop on Corpora for Research on Emotion Sentiment and Social Signals (ES3'2012). 2012. pp. 36–39.
16. Савельева Н.А., Пальчик А.Б., Калашникова Т.П. Особенности довербальной вокализации у плодов и младенцев // Специальное образование. 2022. № 2(66). С. 246–259.
17. Богданова-Бегларян Н.В., Блинова О.В., Зайдес К.Д., Шерстинова Т.Ю. Корпус «Сбалансированная аннотированная текстовка» (CAT): изучение специфики русской монологической речи // Труды института русского языка им. В.В. Виноградова. 2019. № 21. С. 110–126.
18. Богданова-Бегларян Н.В., Шерстинова Т.Ю., Блинова О.В., Мартыненко Г.Я. Корпус «Один речевой день» в исследованиях социолингвистической

- вариативности русской разговорной речи // Анализ разговорной русской речи (АРЗ – 2017): труды седьмого междисциплинарного семинара Санкт-Петербург. 2017. С. 14–20.
19. Кибрик А.А., Подлесская В.И. Коррекция в устной русской монологической речи по данным корпусного исследования // Русский язык в научном освещении. 2006. № 2. С. 7–55.
 20. Kachkovskaia T., Kocharov D., Skrelin P., Volskaya N. CoRuSS – a New Prosodically Annotated Corpus of Russian Spontaneous Speech // Proceedings of the tenth international conference on language resources and evaluation. Portoroz, Slovenia. 2016. pp. 1949–1954.
 21. Кибрик А.А. Русский мультимедийный дискурс. Часть II. Разработка корпуса и направления исследований // Психологический журнал. 2018. № 39(2). С. 79–90.
 22. Pitt M.A., Johnson K., Hume E., Kiesling S., Raymond W. The Buckeye corpus of conversational speech: labeling conventions and a test of transcriber reliability // Speech Communication. 2005. vol. 45(1). no. 1. pp. 89–95.
 23. Baker R., Hazan V. LUCID: a corpus of spontaneous and read clear speech in British English // Proceedings of DiSS-LPSS Joint Workshop. 2010. pp. 3–6.
 24. Polychroniou A., Salamin H., Vinciarelli A. The SSPNet-Mobile Corpus: Social Signal Processing Over Mobile Phones // Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14). 2014. pp. 1492–1498.
 25. Van Engen K.J., Baese-Berk M., Baker R.E., Choi A., Kim M., Bradlow A.R. The Wildcat Corpus of native- and foreign-accented English: communicative efficiency across conversational dyads with varying language alignment profiles // Language and speech. 2010. vol. 53(4). pp. 510–540.
 26. Johnson K.A., Babel M., Fong I., Yiu N. SpiCE: A New Open-Access Corpus of Conversational Bilingual Speech in Cantonese and English // Proceedings of the Twelfth Language Resources and Evaluation Conference. European Language Resources Association (ELRA). 2020. pp. 4089–4095.
 27. Baese-Berk M.M., Morrill T.H. Speaking rate consistency in native and non-native speakers of English // The Journal of the Acoustical Society of America. 2015. vol. 138(3). pp. 223–228.
 28. Janin A., Baron D., Edwards J., Ellis D., Gelbart D., Morgan N., Wooters C. The ICSI Meeting Corpus // IEEE International Conference on Acoustics, Speech, and Signal Processing. 2003. vol. 1. DOI: 10.1109/icassp.2003.1198793.
 29. Chou H.C., Lin W.C., Chang L.C., Li C.C., Ma H.P., Lee C.C. NNIME: The NTHU-NTUA Chinese interactive multimodal emotion corpus // Proceedings of the Seventh International Conference on Affective Computing and Intelligent Interaction (ACII'2017). 2017. pp. 292–298.
 30. Gosy M. BEA – a multifunctional Hungarian spoken language data base // The Phonetician. 2012. vol. 105. pp. 50–61.
 31. Landry Dejoli T.T., He Q., Yan H., Li Y. ASVP-ESD: A dataset and its benchmark for emotion recognition using both speech and non-speech utterances // Global Scientific Journals. 2020. vol. 8(5). pp. 1793–1798.
 32. Baird A., Tzirakis P., Brooks J.A., Gregory C.B., Schuller B., Batliner A., Keltner D., Cowen A. The ACII 2022 Affective Vocal Bursts Workshop & Competition: Understanding a critically understudied modality of emotional expression // 10th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos. 2022.
 33. Petridis S., Martinez B., Pantic M. The MAHNOB Laughter database // Image and Vision Computing. 2013. vol. 31(2). pp. 186–202.

34. Fonseca E., Favory X., Pons J., Font F., Serra X. FSD50K: An Open Dataset of Human-Labeled Sound Events // *IEEE/ACM Transactions on Audio, Speech, and Language Processing*. 2022. vol. 30. pp. 829–852.
35. Gong Y., Yu J., Glass J. Vocalsound: A Dataset for Improving Human Vocal Sounds Recognition // *International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2022. pp. 151–155.
36. Kantharaju R.B., Ringeval F., Besacier L. Automatic recognition of affective laughter in spontaneous dyadic interactions from audiovisual signals // *Proceedings of the ACM 20th International Conference on Multimodal Interaction (ICMI'18)*. 2018. pp. 220–228.
37. Hallmen T., Mertes S., Schiller D., André E. An efficient multitask learning architecture for affective vocal burst analysis // *arXiv preprint arXiv: abs/2209.13914*. 2022.
38. Karas V., Triantafyllopoulos A., Song M., Schuller B.W. Self-Supervised Attention Networks and Uncertainty Loss Weighting for Multi-Task Emotion Recognition on Vocal Bursts // *The 2022 ACII Affective Vocal Burst Workshop & Challenge (A-VB)*. 2022. vol. 45(1). pp. 89–95.
39. Liu S., Johns E., Davison A.J. End-to-end multi-task learning with attention // *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2019. pp. 1871–1880.
40. Nguyen D.-K., Pant S., Ho N.-H., Lee G.-S., Kim S.-H., Yang H.-J. Fine-tuning Wav2vec for Vocal-burst Emotion Recognition // *The 2022 ACII Affective Vocal Burst Workshop & Challenge (A-VB)*. 2022. vol. 45(1). pp. 89–95.
41. Pratap V., Xu Q., Sriram A., Synnaeve G., Collobert R. MLS: a large-scale multilingual dataset for speech research // *Proceedings of INTERSPEECH*. 2020. pp. 2757–2761.
42. Ardila R., Branson M., Davis K., Henretty M., Kohler M., Meyer J., Morais R., Saunders L., Tyers F.M., Weber G. Common voice: a massively-multilingual speech corpus // *Proceedings of the 12th Conference on Language Resources and Evaluation (LREC'2020)*. 2020. pp. 4218–4222.
43. Gales M.J.F., Knill K., Ragni A., Rath S.P. Speech recognition and keyword spotting for low-resource languages: babel project research at cued // *Proceedings 4th Workshop on Spoken Language Technologies for Under-Resourced Languages (SLTU'2014)*. 2012. pp. 16–23.
44. Vaessen N., Van Leeuwen D.A. Fine-tuning wav2vec2 for speaker recognition // *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2022. pp. 7967–7971.
45. Kahn J., Riviere M., Zheng W., Kharitonov E., Xu Q., Mazare P.-E., Karaday J., Liptchinsky V., Collobert R., Fuegen C., et al. Libri-light: A benchmark for asr with limited or no supervision // *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2020. pp. 7669–7673.
46. Lotfian R., Busso C. Building naturalistic emotionally balanced speech corpus by retrieving emotional speech from existing podcast recordings // *IEEE Transactions on Affective Computing*. 2019. vol. 10. no. 4. pp. 471–483.
47. Panayotov V., Chen G., Povey D., Khudanpur S. LibriSpeech: an ASR corpus based on public domain audio books // *IEEE international conference on acoustics, speech and signal processing (ICASSP)*. 2015. pp. 5206–5210.
48. Schuller B., Steidl S., Batliner A., Vinciarelli A., Scherer K., Ringeval F., Chetouani M., Weninger F., Eyben F., Marchi E., Mortillaro M., Salamin H., Polychroniou A., Valente F., Kim S. The INTERSPEECH 2013 computational paralinguistics challenge: social signals, conflict, emotion, autism // *Proceedings of the 14th Annual*

- Conference of the International Speech Communication Association. 2013. pp. 148–152.
49. Hall M., Frank E., Holmes G., Pfahringer B., Reutemann P., Witten I.H. The WEKA data mining software: An update // *ACM SIGKDD Explorations Newsletter*. 2009. vol. 11. no. 1. pp. 10–18.
 50. Brueckner R., Schuller B. Social signal classification using deep BLSTM recurrent neural networks // *International conference on acoustics, speech and signal processing (ICASSP)*. 2014. pp. 4823–4827.
 51. Eyben F., Wollmer M., Schuller B. Opensmile: The munich versatile and fast open-source audio feature extractor // *Proceedings 18th ACM International Conference Multimedia*. 2010. pp. 1459–1462.
 52. Gupta R., Audhkhasi K., Lee S., Narayanan S. Detecting paralinguistic events in audio stream using context in features and probabilistic decisions // *Computer Speech & Language*. 2016. vol. 36. pp. 72–92.
 53. Gosztoya G. Optimized Time Series Filters for Detecting Laughter and Filler Events // *INTERSPEECH*. 2017. pp. 2376–2380.
 54. Hansenand N., Ostermeier A. Completely derandomized selfadaptation in evolution strategies // *Evolutionary Computation*. 2001. vol. 9. no. 2. pp. 159–195.

Поволоцкая Анастасия Андреевна — младший научный сотрудник, аспирант, лаборатория речевых и многомодальных интерфейсов, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: искусственный интеллект, машинное обучение, нейронные сети, автоматическое распознавание речи, компьютерная лингвистика. Число научных публикаций — 3. anastasiia.povolotskaia@gmail.com; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Карпов Алексей Анатольевич — д-р техн. наук, профессор, руководитель лаборатории, лаборатория речевых и многомодальных интерфейсов, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: речевые технологии, автоматическое распознавание речи, обработка аудиовизуальной речи, многомодальные человеко-машинные интерфейсы, компьютерная паралингвистика и другие. Число научных публикаций — 350+. karpov@iias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Поддержка исследований. Данное исследование выполнено в рамках Ведущей научной школы РФ (Грант № НШ-17.2022.1.6), а также частично в рамках бюджетной темы СПб ФИЦ РАН (№ FFZF-2022-0005).

A. POVOLOTSKAIA, A. KARPOV
**ANALYTICAL REVIEW OF METHODS FOR AUTOMATIC
ANALYSIS OF EXTRA-LINGUISTIC UNITS IN SPONTANEOUS
SPEECH**

Povolotskaia A., Karpov A. Analytical Review of Methods for Automatic Analysis of Extra-Linguistic Units in Spontaneous Speech.

Abstract. The accuracy of automatic spontaneous speech recognition systems is far from that of trained speech recognition systems. This is due to the fact that spontaneous speech is not as smooth and failure-free as spontaneous speech. Spontaneous speech varies from speaker to speaker: the quality of phonemes' pronunciation, the presence of pauses, speech disruptions and extralinguistic items (laughing, coughing, sneezing, and chuckling when expressing emotions of irritation, etc.) interrupt the fluency of verbal speech. However, it is worth noting that extralinguistic items very often carry important paralinguistic information, so it is crucial for automatic spontaneous speech recognition systems not only to identify such phenomena and distinguish them from the verbal components of speech but also to classify them. This review presents an analysis of works on the topic of automatic detection and analysis of extralinguistic items in spontaneous speech. Both individual methods and approaches to the recognition of extralinguistic items in a speech stream, and works related to the multiclass classification of isolatedly recorded extralinguistic units are considered and described. The most popular methods of extralinguistic units' analysis are neural networks, such as deep neural networks and networks based on transformer models. The basic concepts related to the term extralinguistic items are given, the original systematization of extralinguistic items in the Russian language is proposed, the corpus and databases of audio spoken speech both in Russian and in other languages are described, the data sets of extralinguistic items recorded isolatedly are also given. The accuracy of extralinguistic items recognition increases with the following conditions of work with the speech signal: pre-processing of audio signals of items has shown an increase in the accuracy of separately recorded extralinguistic items classification; consideration of context (analysis of several frames of speech signal) and use of filters for smoothing the time series after extraction of feature vectors showed an increase in accuracy in frame-by-frame analysis of the speech signal with spontaneous speech.

Keywords: automatic speech recognition, speech technology, machine learning, linguistics, extralinguistic units, spontaneous speech, automatic extralinguistic units recognition.

References

1. Verkhodanova V., Karpov A., Kipyatkova I., Shapranov V. [Automatic detection of vocalized hesitations in Russian speech]. *Voprosy Jazykoznanija – Questions of linguistics*. 2018. no. 6. pp. 104–118. (In Russ.).
2. Ataollahi F., Suarez M.T. Laughter Classification Using 3D Convolutional Neural Networks. *Proceedings of the 3rd International Conference on Advances in Artificial Intelligence (ICAAI '19)*. 2019. pp. 47–51.
3. Sudjenkova A.V. [Overview of methods for extracting acoustic speech features in speaker recognition]. *Sbornik nauchnyh trudov NGTU – Transaction of scientific papers of the Novosibirsk state technical university*. 2019. no. 3–4. pp. 139–164. (In Russ.).

4. Hsu J.-H., Su M.-H., Wu C.-H., Chen Y.-H. Speech Emotion Recognition Considering Nonverbal Vocalization in Affective Conversations. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*. 2021. vol. 29. pp. 1675–1686.
5. Dumpala S.H., Alluri K.N.R.K.R. An Algorithm for Detection of Breath Sounds in Spontaneous Speech with Application to Speaker Recognition. *Speech and Computer: 19th International Conference (SPECOM)*. 2017. pp. 98–108.
6. Huang K.-Y., Wu C.-H., Hong Q.-B., Su M.-H., Chen Y.-H. Speech Emotion Recognition Using Deep Neural Network Considering Verbal and Nonverbal Speech Sounds. *International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2019. pp. 5866–5870.
7. Kuluozturk M., Kobat M.A., Barua P.D., Dogan S., Tuncer T., Tan R.S., Ciaccio E.J., Acharya U.R. DKPNet41: Directed knight pattern network-based cough sound classification model for automatic disease diagnosis. *Medical engineering and physics*. 2022. vol. 110. no. 103870.
8. Lahmiri S., Tadj C., Gargour C., Bekiros S. Deep learning systems for automatic diagnosis of infant cry signals. *Chaos, Solitons & Fractals*. 2022. vol. 154. no. 111700.
9. Matikolaie F.S., Tadj C. Machine Learning-Based Cry Diagnostic System for Identifying Septic Newborns. *Journal of Voice*. 2022. DOI: 10.1016/j.jvoice.2021.12.021.
10. Matsuda T., Arimoto Y. Detection of laughter and screaming using the attention and ctc models. *Proceedings of INTERSPEECH 2023*. pp. 1025–1029. DOI: 10.21437/Interspeech.2023-1412.
11. Ortega D., Meyer S., Schweitzer A., Vu N.T. Modeling Speaker-Listener Interaction for Backchannel Prediction. *13th International Workshop on Spoken Dialogue Systems Technology*. 2023. pp. 1–16.
12. Lea C., Huang Z., Jain D., Tooley L., Liaghat Z., Thelapurath S., Findlater L., Bigham J.P. Nonverbal Sound Detection for Disordered Speech. *International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2022. pp. 7397–7401.
13. Crystal D. *Prosodic Systems and Intonation in English*. Cambridge University Press, 1969. 390 p.
14. Simon-Thomas E., Sauter D., Sinicropi-Yao L., Abramson A., Keltner D. Vocal Bursts Communicate Discrete Emotions: Evidence for New Displays. *Nature Proceedings*. 2007. DOI: 10.1038/npre.2007.1356.1.
15. Trouvain J., Truong K.P. Comparing non-verbal vocalisations in conversational speech corpora. *Proceedings of the 4th International Workshop on Corpora for Research on Emotion Sentiment and Social Signals (ES3'2012)*. 2012. pp. 36–39.
16. Savel'eva N.A., Pal'chik A.B., Kalashnikova T.P. [Specific features of preverbal vocalizations in fetuses and infants]. *Special'noe obrazovanie – Special Education*. 2022. no. 2(66). pp. 246–259. (In Russ.).
17. Bogdanova-Beglarjan N.V., Blinova O.V., Zajdes K.D., Sherstinova T.Ju. [Corpus “Balanced annotated text collection (textoteca)” (SAT): studying the specificity of russian monological speech]. *Trudy instituta russkogo jazyka im. V.V. Vinogradova – Proceedings of the V.V. Vinogradov Institute of Russian Language*. Vinogradov. 2019. no. 21. pp. 110–126. (In Russ.).
18. Bogdanova-Beglarjan N.V., Sherstinova T.Ju., Blinova O.V., Martynenko G.Ja. [Corpus «One Speech Day» in studies of sociolinguistic variation in Russian colloquial speech] *Analiz razgovornoj ruskoj rechi (AR3 – 2017): Trudy sed'mogo*

- mezhdisciplinarnogo seminaru [Analysis of the Russian colloquial speech: Collected papers]. St Petersburg: St Petersburg State University, 2017. pp. 14–20. (In Russ.).
19. Kibrik A.A., Podlesskaja V.I. Correction in Russian spoken monologues: a corpus study. *Russkii yazyk v nauchnom osveshchenii – Russian Language and Linguistic Theory*. 2006. no. 2. pp. 7–55. (In Russ.).
 20. Kachkovskaia T., Kocharov D., Skrelin P., Volskaya N. CoRuSS – a New Prosodically Annotated Corpus of Russian Spontaneous Speech. Proceedings of the tenth international conference on language resources and evaluation. Portoroz, Slovenia. 2016. pp. 1949–1954.
 21. Kibrik A.A. [Russian Multichannel Discourse. Part II. Development of the corpus and directions of research]. *Psihologicheskij zhurnal – Journal of Psychology*. 2018. no. 39(2). pp. 79–90. (In Russ.).
 22. Pitt M.A., Johnson K., Hume E., Kiesling S., Raymond W. The Buckeye corpus of conversational speech: labeling conventions and a test of transcriber reliability. *Speech Communication*. 2005. vol. 45(1). no. 1. pp. 89–95.
 23. Baker R., Hazan V. LUCID: a corpus of spontaneous and read clear speech in British English. Proceedings of DiSS-LPSS Joint Workshop. 2010. pp. 3–6.
 24. Polychroniou A., Salamin H., Vinciarelli A. The SSPNet-Mobile Corpus: Social Signal Processing Over Mobile Phones. Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14). 2014. pp. 1492–1498.
 25. Van Engen K.J., Baese-Berk M., Baker R.E., Choi A., Kim M., Bradlow A.R. The Wildcat Corpus of native- and foreign-accented English: communicative efficiency across conversational dyads with varying language alignment profiles. *Language and speech*. 2010. vol. 53(4). pp. 510–540.
 26. Johnson K.A., Babel M., Fong I., Yiu N. SpiCE: A New Open-Access Corpus of Conversational Bilingual Speech in Cantonese and English. Proceedings of the Twelfth Language Resources and Evaluation Conference. European Language Resources Association (ELRA). 2020. pp. 4089–4095.
 27. Baese-Berk M.M., Morrill T.H. Speaking rate consistency in native and non-native speakers of English. *The Journal of the Acoustical Society of America*. 2015. vol. 138(3). pp. 223–228.
 28. Janin A., Baron D., Edwards J., Ellis D., Gelbart D., Morgan N., Wooters C. The ICSI Meeting Corpus. IEEE International Conference on Acoustics, Speech, and Signal Processing. 2003. vol. 1. DOI: 10.1109/icassp.2003.1198793.
 29. Chou H.C., Lin W.C., Chang L.C., Li C.C., Ma H.P., Lee C.C. NNIME: The NTHU-NTUA Chinese interactive multimodal emotion corpus. Proceedings of the Seventh International Conference on Affective Computing and Intelligent Interaction (ACII'2017). 2017. pp. 292–298.
 30. Gosy M. BEA – a multifunctional Hungarian spoken language data base. *The Phonetician*. 2012. vol. 105. pp. 50–61.
 31. Landry Dejoli T.T., He Q., Yan H., Li Y. ASVP-ESD: A dataset and its benchmark for emotion recognition using both speech and non-speech utterances. *Global Scientific Journals*. 2020. vol. 8(5). pp. 1793–1798.
 32. Baird A., Tzirakis P., Brooks J.A., Gregory C.B., Schuller B., Batliner A., Keltner D., Cowen A. The ACII 2022 Affective Vocal Bursts Workshop & Competition: Understanding a critically understudied modality of emotional expression. 10th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos. 2022.
 33. Petridis S., Martinez B., Pantic M. The MAHNOB Laughter database. *Image and Vision Computing*. 2013. vol. 31(2). pp. 186–202.
 36. Информатика и автоматизация. 2024. Том 23 № 1. ISSN 2713-3192 (печ.)
ISSN 2713-3206 (онлайн) www.ia.spcras.ru

34. Fonseca E., Favory X., Pons J., Font F., Serra X. FSD50K: An Open Dataset of Human-Labeled Sound Events. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*. 2022. vol. 30. pp. 829–852.
35. Gong Y., Yu J., Glass J. Vocalsound: A Dataset for Improving Human Vocal Sounds Recognition. *International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2022. pp. 151–155.
36. Kantharaju R.B., Ringeval F., Besacier L. Automatic recognition of affective laughter in spontaneous dyadic interactions from audiovisual signals. *Proceedings of the ACM 20th International Conference on Multimodal Interaction (ICMI'18)*. 2018. pp. 220–228.
37. Hallmen T., Mertes S., Schiller D., André E. An efficient multitask learning architecture for affective vocal burst analysis. *arXiv preprint arXiv: abs/2209.13914*. 2022.
38. Karas V., Triantafyllopoulos A., Song M., Schuller B.W. Self-Supervised Attention Networks and Uncertainty Loss Weighting for Multi-Task Emotion Recognition on Vocal Bursts. *The 2022 ACII Affective Vocal Burst Workshop & Challenge (A-VB)*. 2022. vol. 45(1). pp. 89–95.
39. Liu S., Johns E., Davison A.J. End-to-end multi-task learning with attention. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2019. pp. 1871–1880.
40. Nguyen D.-K., Pant S., Ho N.-H., Lee G.-S., Kim S.-H., Yang H.-J. Fine-tuning Wav2vec for Vocal-burst Emotion Recognition. *The 2022 ACII Affective Vocal Burst Workshop & Challenge (A-VB)*. 2022. vol. 45(1). pp. 89–95.
41. Pratap V., Xu Q., Sriram A., Synnaeve G., Collobert R. MLS: a large-scale multilingual dataset for speech research. *Proceedings of INTERSPEECH*. 2020. pp. 2757–2761.
42. Ardila R., Branson M., Davis K., Henretty M., Kohler M., Meyer J., Morais R., Saunders L., Tyers F.M., Weber G. Common voice: a massively-multilingual speech corpus. *Proceedings of the 12th Conference on Language Resources and Evaluation (LREC'2020)*. 2020. pp. 4218–4222.
43. Gales M.J.F., Knill K., Ragni A., Rath S.P. Speech recognition and keyword spotting for low-resource languages: babel project research at cued. *Proceedings 4th Workshop on Spoken Language Technologies for Under-Resourced Languages (SLTU'2014)*. 2012. pp. 16–23.
44. Vaessen N., Van Leeuwen D.A. Fine-tuning wav2vec2 for speaker recognition. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2022. pp. 7967–7971.
45. Kahn J., Riviere M, Zheng W., Kharitonov E., Xu Q., Mazare P.-E., Karaday J., Liptchinsky V., Collobert R., Fuegen C., et al. Libri-light: A benchmark for asr with limited or no supervision. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2020. pp. 7669–7673.
46. Lotfian R., Busso C. Building naturalistic emotionally balanced speech corpus by retrieving emotional speech from existing podcast recordings. *IEEE Transactions on Affective Computing*. 2019. vol. 10. no. 4. pp. 471–483.
47. Panayotov V., Chen G., Povey D., Khudanpur S. LibriSpeech: an ASR corpus based on public domain audio books. *IEEE international conference on acoustics, speech and signal processing (ICASSP)*. 2015. pp. 5206–5210.
48. Schuller B., Steidl S., Batliner A., Vinciarelli A., Scherer K., Ringeval F., Chetouani M., Weninger F., Eyben F., Marchi E., Mortillaro M., Salamin H., Polychroniou A., Valente F., Kim S. The INTERSPEECH 2013 computational paralinguistics challenge: social signals, conflict, emotion, autism. *Proceedings of the 14th Annual*

- Conference of the International Speech Communication Association. 2013. pp. 148–152.
49. Hall M., Frank E., Holmes G., Pfahringer B., Reutemann P., Witten I.H. The WEKA data mining software: An update. *ACM SIGKDD Explorations Newsletter*. 2009. vol. 11. no. 1. pp. 10–18.
 50. Brueckner R., Schuller B. Social signal classification using deep BLSTM recurrent neural networks. *International conference on acoustics, speech and signal processing (ICASSP)*. 2014. pp. 4823–4827.
 51. Eyben F., Wollmer M., Schuller B. Opensmile: The munich versatile and fast open-source audio feature extractor. *Proceedings 18th ACM International Conference Multimedia*. 2010. pp. 1459–1462.
 52. Gupta R., Audhkhasi K., Lee S., Narayanan S. Detecting paralinguistic events in audio stream using context in features and probabilistic decisions. *Computer Speech & Language*. 2016. vol. 36. pp. 72–92.
 53. Gosztołya G. Optimized Time Series Filters for Detecting Laughter and Filler Events. *INTERSPEECH*. 2017. pp. 2376–2380.
 54. Hansenand N., Ostermeier A. Completely derandomized selfadaptation in evolution strategies. *Evolutionary Computation*. 2001. vol. 9. no. 2. pp. 159–195.

Povolotskaia Anastasiia — Junior researcher, postgraduate student, Speech and multimodal interfaces laboratory, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: artificial intelligence, machine learning, neural networks, automatic speech recognition, computer linguistics. The number of publications — 3. anastasiia.povolotskaia@gmail.com; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0421.

Karpov Alexey — Ph.D., Dr.Sci., Professor, Head of the laboratory, Speech and multimodal interfaces laboratory, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: speech technology, automatic speech recognition, audio-visual speech processing, multimodal human-computer interfaces, and computational paralinguistics. The number of publications — 350+. karpov@iias.spb.su; 39, 14-th Line V.O., 199178, Saint-Petersburg, Russia; office phone: +7(812)328-0421.

Acknowledgements. This research was partially supported by the Leading scientific school of Russia (Grant no. NSH-17.2022.1.6), as well as partially by the state research of SPC RAS (Topic no. FFZF-2022-0005).

G. JANARDANA NAIDU, M. SESHASHAYEE
**SENTIMENT ANALYSIS FRAMEWORK FOR TELUGU TEXT
BASED ON NOVEL CONTRIVED PASSIVE AGGRESSIVE WITH
FUZZY WEIGHTING CLASSIFIER (CPSC-FWC)**

Naidu G., Seshashayee M. Sentiment Analysis Framework for Telugu Text Based on Novel Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC).

Abstract. Natural language processing (NLP) is a subset of artificial intelligence demonstrating how algorithms can interact with individuals in their unique languages. In addition, sentiment analysis in NLP is better in numerous programs, including evaluating sentiment in Telugu. Several unsupervised machine-learning algorithms, such as k-means clustering with cuckoo search, are used to detect Telugu text. However, these techniques struggle to cluster data with variable cluster sizes and densities, slow search speeds, and poor convergence accuracy. This study developed a unique ML-based sentiment analysis system for Telugu text to address the shortcomings. Initially, in the pre-processing stage, the proposed Linear Pursuit Algorithm (LPA) removes words in white spaces, punctuation, and stops. Then, for POS tagging, this research proposed a Conditional Random Field with Lexicon weighting; following that, a Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC) is proposed to classify the sentiments in Telugu text. Consequently, the method we propose produces efficient outcomes in terms of accuracy, precision, recall, and f1-score.

Keywords: machine learning, natural language processing, polarity, sentiment analysis, Telugu.

1. Introduction. NLP is both a study and a topic which examines how computers can comprehend and adapt natural language text or speech to do useful tasks [1 – 4]. NLP scientists try to learn further about how people understand and use language to ensure suitable technology and methods can be developed to assist computers in perceiving and manipulating natural languages to do the required tasks. Sentiment analysis is an NLP technique that examines a person's emotions, sentiments, and opinions on various items, including products, films, events, reports, and businesses [5]. The main goal of sentiment analysis is to identify the polarity of a text within a given resource. Positive, negative, and neutral polarities are all conceivable.

In addition, there are three layers of sentiment analysis for text: sentence level, document level, and aspect level [6]. The goal of sentence-level analysis is to determine the polarity importance of each sentence in the examined material. Lexicon-based methods, along with Machine Learning (ML) [7] techniques, are the two basic approaches to Sentiment Analysis (SA). The lexicon-based technique analyses the text data by applying a sentiment lexicon for keyword matching. Word sentiment information can be found in lexicons. In [15] the authors suggested SenticNet, and in study [14] suggested SentiWordNet as examples of the

lexicon. Lexicon alone fails to deliver high accuracy, yet when combined with the Semantic Rule [16, 17], good results are obtained [19]. Semantic rules are used to deal with language exceptions like negation. It positively affects the categorisation of polarities. However, the method necessitates the human definition of Semantic Rules.

Furthermore, the polarity value is established by document-level analysis according to content evaluation. To determine the polarity of each text feature, aspect-level analysis (word-by-word) is performed [18]. While document categorization is less common than short text analysis along with social network evaluation, it could prove quite beneficial in a variety of situations, including the research of political views [20] displayed in the media, the analysis of feedback from consumers [21], with news coverage. Then there's "NLP," a discipline of AI that shows how techniques may connect with people utilizing their native languages. Considering the proliferation of fabricated reports then the growth of internet platforms, mining Telugu news data and classifying it depending on public sentiment is critical. The Stanford Sentiment Treebank – 2 (SST-2) dataset is extensively utilized for sentiment analysis (SA), and Bidirectional Encoder Representations from Transformers (BERT) outperform previous modern methods in this field [8]. Bataa and Wu [11] used BERT and transferable learning methodologies to achieve a new state-of-the-art Japanese SA.

Despite its efficacy in basic sentiment categorization, aspect-based sentiment analysis (ABSA), an enhanced SA task, showed less significant improvement when BERT was directly applied [9]. In paper [9] the authors created an auxiliary phrase to use BERT's powerful representation more by transforming Aspect Based Sentiment Analysis (ABSA) from a single-sentence classification issue to a sentence pair classification challenge. Furthermore, study [12] suggested that the BERT might profit from the addition of a pooling component, which might be performed as a Long Short Term Memory (LSTM) or an attention mechanism to use the BERT's intermediate levels for ABSA [13].

The amount of variables used in models has increased dramatically due to the introduction of Deep Learning (DL) [12]. A substantially bigger dataset is necessary to train the model's variables entirely while avoiding overfitting. Creating large-scale labelled datasets, nevertheless, is a substantial obstacle for the bulk of NLP positions owing to the relatively high annotation costs, especially for semantically and syntactically related jobs. In earlier research [22], we studied the efficacy of Convolutional Neural Network (CNN) and LSTM methods for lengthy text and observed that combining Doc2vec and CNN models generated

marginally superior outcomes than RNN. It is required so that CNN may use the Doc2Vec models to identify the polarities of the entire work.

Telugu is India's second most frequently spoken language, behind Hindi. Following Ethnologue, Telugu is the fifteenth most frequently spoken dialect globally, with 85 million native Telugu speakers globally [23]. Several Telugu-language electronic newspapers publish news daily, including Eenadu, Sakshi, Andhrajyothy, Vaartha, and Andhrabhoomi, among others. Telugu material is prevalent on most news websites, web journals, Twitter accounts, and other social media platforms. Therefore, it is important to analyse the feelings underlying Telugu news.

Natural language processing has benefited considerably from data mining techniques [24]. Application for Knowledge Discovery in Real Time, such as Clinical Analysis [25], to proceed with comprehending the prediction methods, Association Rule Mining in the Business of Marketing [26], and the System of Education, demand a lean towards information disclosure techniques. The advent of ML and DL in NLP simplified and practicalized the difficult and tedious work of constructing perceives [23]. The following is the primary contribution of this study:

After collecting the Annotated Corpus of Telugu Sentiment Analysis (ACTSA) Telugu annotation dataset, the following steps were taken to ensure good quality input data for our machine learning models.

In the pre-processing stage Split () function is utilized to split the sentences into words based on the white spaces and punctuation. Then, we removed the words with no information (stop words) and special characters by using our proposed Linear Pursuit Algorithm (LPA). We balanced the dataset by using our proposed Adaptive Synthetic Sampling (ADASYN) approach.

- Then, this research proposed a Conditional Random Field (CRF) with Lexicon weighting for POS tagging.

- Then, to classify the Telugu text, this research proposed Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC). Consequently, the suggested CPSC-FWC framework classifies emotion as positive, negative, or neutral.

- This research article is organised as follows: The third part discusses the proposed machine learning-based approach after a study of the present sentiment analysis for various article phrases in Part 2. Section 4 examines the implementation outcomes briefly, and Section 5 concludes this study piece.

2. Literature Survey. Utilising Telugu SentiWordNet, in paper [27] the authors presented a two-phase sentiment analysis for

Telugu news phrases. It first identifies subjectivity categorization, categorising statements as subjective or objective. Objective sentences are considered to have neutral feelings because they lack any emotive value. As part of the Sentiment Classification procedure, the subjective statements are separated into positive and negative sentences. However, the accuracy of this study is lacking, as is the ability to develop another technique for creating this SentiwordNet dynamic in the future.

Study [28] adopted a rule-based methodology to create SentiPhraseNet. SentiPhraseNet was used to extract the sentiment in this case, and the results were confirmed using the annotated corpus data set ACTSA. SentiPhrasenet does not include all possible phrases.

Paper [29] used ML methods with a knowledge-based strategy to develop a Telugu-language Word Sense Disambiguation (WSD) framework. Lexical Knowledge Base (LKB) is the information source for developing the WSD system. Disambiguation of words is still in the early stages, and little research has been published. Telugu has greater potential for word sense disambiguation than every other regional dialect nowadays. An unsupervised method can develop an upcoming word sense disambiguation algorithm for the local Telugu language.

In paper [30] the authors used ML classifiers to create an effective framework for classifying Telugu news data. In the authors' work, ML classifiers, including Multinomial Nave Bayes, Random Forest, Passive Aggressive Classifier, Perceptron, and Support Vector Machine (SVM), address the challenge of categorizing news sentiments in Telugu. A dataset is acquired via the open-source Kaggle platform. DL methodologies, including Recurrent Neural Network (RNN) and LSTM framework, will be used to discover the attitudes. It is also possible to extend the work to examine the news sentiments in Malayalam, Kannada, Tamil, and Urdu.

In study [31] the authors investigated numerous unsupervised machine-learning techniques for categorising Telugu text into either negative or positive classifications. Cuckoo search's superiority over K-means in locating the cluster's centroid is the explanation behind this. Next, research might look at more unsupervised techniques to find a viable solution for sentiment analysis in Telugu.

In [32] the authors planned to broaden a unique Evolving C4.5 ML with Spider Monkey Optimization (EC4.5-ML-SMO) to categorize sentiment evaluation in the Telugu language successfully. Spider Monkey Optimization is a contemporary-inspired technique defined by Swarm Intelligence Approaches. This approach is being employed in the present study to improve the accuracy of sentiment categorization. Furthermore,

the bioinspired structure has its fitness that is determined by its behaviour. As a result, the current study evolved a novel hybrid system learning model for validating the client summary in the Telugu dataset. Iteration, on the other hand, requires more time.

Study [33] systematically classified views in Telugu using a lexicon-based methodology with ML in sentiment analysis. First, we detected subjective phrases from the Telugu corpus using a Lexicon-based technique called Telugu SentiWordNet. Second, we classified the sentiment in the corpus using ML methods such as SVM, Naive Bayes, and Random Forest.

Hence, the existing research utilized a rule-based methodology to create SentiPhraseNet. However, Sentiphrasenet does not include all possible phrases. Then, to classify the Telugu text, various unsupervised ML algorithms such as k-means clustering and cuckoo search algorithm are used; however, k-means has difficulty clustering data with varying cluster sizes and density, and the cuckoo method has the drawbacks of slow search speed and low convergence accuracy. This study created a special network, which is covered in more detail in the following section, to overcome the above-mentioned disadvantages.

3. Proposed Approach. The following are the steps of an innovative ML-based sentiment analysis tool for Telugu text. Stage I: we collected the ACTSA Telugu annotated dataset, and then the datasets were pre-processed using the proposed Linear Pursuit Algorithm. Hence we removed the white spaces, punctuation, and stop words and balanced the dataset by using our proposed Adaptive Synthetic Sampling (ADASYN) approach. In Stage II, a Conditional Random Field with Lexicon weighting is proposed for parts of speech tagging. Then, the processed data are fed into the proposed Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC) is described in Stage III. Therefore, the proposed CPSC-FWC framework classifies emotion as positive, negative, or neutral. Figure 1 displays the proposed approach's design.

Dataset Description. In this part, we will peek at the places where the initial information was received. Our source data was collected from five distinct Telugu news websites: Andhra Bhoomi, Andhra-Jyothi, Eenadu, Kridajyothi, and Saakshi. The writers gathered over 453 news pieces and whittled them down to 321.

Annotators labelled all of the statements, with every statement annotated by precisely two annotators (Table 1).

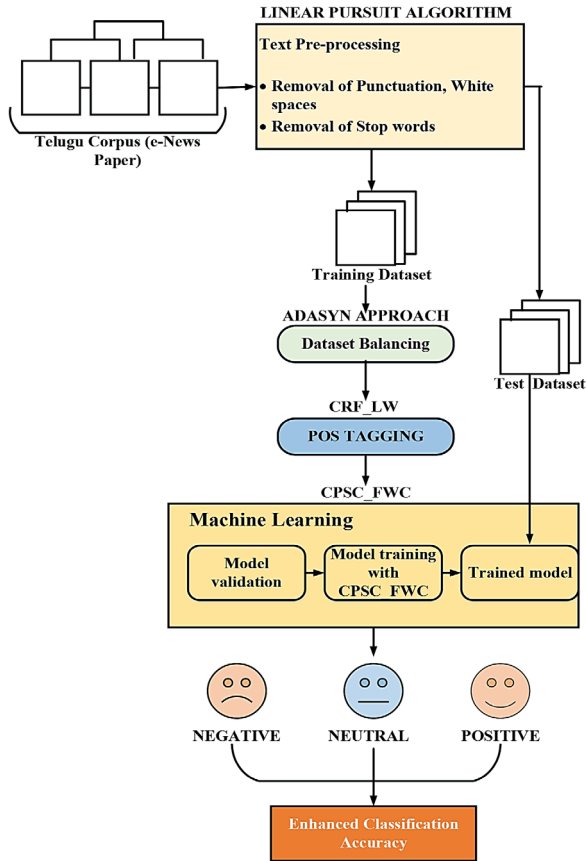


Fig. 1. Architecture of the proposed approach

Table 1. Example Annotations

ID	Original Sentence	English Translation	Class
1	అమెరికా అధ్యక్షుడు డొనాల్డ్ ట్రంప్ పారిస్ నుంచి అమెరికాను ఉపసంహరించుకున్నాడు. సహచరుడు ఒప్పందం	US President Donald Trump withdrew the US from the Paris Climate Agreement	Negative
2	అవసరం లేదు ఇందులో ఎవరికైనా ఏదైనా అభ్యంతరం	There is no need for any objection to any- one in this	Neutral
3	భారతదేశ ప్రధాన మంత్రి కశ్మీర్ ఆల్లర్లపై నరంధ్ర మోడీ తీవ్రంగా స్పందించారు	India's Prime Minister Narendra Modi has re- acted severely to the Kashmir riots	Negative
4	మంత్రి సంతోషించారు పరితాలపై	The minister is happy on the results	Positive

Sentences deemed ambiguous by at least one annotator were removed from the corpus to avoid unclear sentences. Table 2 displays several corpus annotation examples.

Table 2. Agreement for Sentences in ACTSA

Annotator	Positive	Negative	Neutral	Total
Positive	1463	31	103	1597
Negative	23	1421	116	1560
Neutral	112	127	2427	2666
Total	1598	1579	2646	5823

Our data statistics, from raw data collecting to the last words. The writers gathered 453 news stories and whittled them down to 321 associated with their study area. The writers have 11952 sentences in their initial information. The researchers then examined the statements for subjectivity and deleted 4327 objective sentences, leaving 7812 sentences. The annotators were given these sentences to annotate. There were 1802 sentences eliminated because a minimum of one annotator identified them as questionable. Of the remaining 5823 sentences, 512 were in dispute and were referred to a third independent annotation. Following the third annotation, 413 sentences were deleted if there was a dispute or if they were objective. The annotated corpus requested by ACTSA is made up of the other 5405 sentences. Table 3 gives statistics for our whole corpus. Following the third annotation, 413 contested or objective sentences were eliminated. The annotated corpus requested by ACTSA is made up of the remaining 5405 sentences. Table 3 gives statistics for our whole corpus.

Table 3. Statistics about the data

News articles	321
Cleaned Sentences	11952
Objective Sentences (Removed)	4327
Uncertain Sentences (Removed)	1802
Disagreement Sentences	512
Classified	99
Removed	413
Positive sentences	1489
Negative sentences	1441
Neutral sentences	2475
Total sentences	5405

In the pre-processing stage, the information received was cleaned, for example, by deleting punctuation and removing phrases with non-Telugu terms, excess spaces, URLs, and other trash values. Later, Sentence Segmentation is conducted after all of this info is separated into discrete sentences. The initial data corpus is split between 90% training and 10% test datasets.

Pre-processing. We took the following measures to secure high-quality input data for our ML models (Table 4).

Table 4. Example of the pre-processed Telugu sentence

Original Telugu Sentence	Pre-processed Sentence	Polarity (1, 0, -1)
పరువునష్టాన్ని కలిగించే చర్యలను 1860 నాటి భారత శిక్షాస్ఫూటిలోని సెక్షన్ 499 నిర్వచించగా, అందుకు విధించగలిగిన శిక్షను, జరిమానాను సెక్షన్ 500 పేర్కొన్నది.	'పరువునష్టాన్ని ' 'కలిగించే ' 'చర్యలను ' '1860 ' 'నాటి ' 'భారత ' 'శిక్షాస్ఫూటిలోని ' 'సెక్షన్ ' '499 ' 'నిర్వచించగా, ' 'అందుకు ' 'విధించగలిగిన ' 'శిక్షను, ' 'జరిమానాను ' 'సెక్షన్ ' '500 ' 'పేర్కొన్నది '	0
వాహనంలో ఉన్న పోలీసు సిబ్బందికి బుల్లెట్ పూప్ కవచాలు లేవన్నది అటువంటి, వారు ఏమాత్రం అప్రమత్తంగా లేరన్నది కూడా వాస్తవం ఎవరైనా	'వాహనంలో ' 'ఉన్న ' 'పోలీసు ' 'సిబ్బందికి ' 'బుల్లెట్ ' 'పూప్ ' 'కవచాలు ' 'లేవన్నది ' 'అటువంటి ' 'వారు ' 'ఏమాత్రం ' 'అప్రమత్తంగా ' 'లేరన్నది ' 'కూడా ' 'వాస్తవం '	1
దేశంపట్ల కానీ, ప్రజలపట్ల కానీ బాధ్యత కనిపించదు	'దేశంపట్ల ' 'కానీ ' 'ప్రజలపట్ల ' 'కానీ ' 'బాధ్యత ' 'కనిపించదు '	-1

In the pre-processing stage Split () function is utilized to split the sentences into words based on the white spaces and punctuation. Here, we will separate the text by all commonly used characters, such as "." and "/n," then, given two sentences, the model will determine whether they should be combined. As a result, the model will provide us with a new sentence-by-sentence breakdown of the text.

Then, we removed the words with no information (stop words) and special characters by using our proposed Linear Pursuit Algorithm (LPA) (Algorithm 1, Table 5). It searches all the elements in the datasets sequentially. First, it checks for the first sentence; if the sentence has to stop words, it will remove them. Otherwise, it continues for n sentences; by doing this, we obtain an accurate dataset with less memory usage. The most fundamental search method is linear search, also called sequential search. This type of search entails searching the complete list (Telugu dataset) for a match for a particular component. If a match is detected, the stop words of the matched target component are sent back. On the contrary, if the component cannot be found, it returns NULL. The following is a step-by-step procedure for doing the Linear Pursuit Procedure:

- First, read the search sentence (Stop words) in the dataset.
- The stop words are compared to the initial phrase in the array in the next stage.
- If both are matched, the Linear Pursuit function will be terminated and the message "Stop word found" will be shown.
- If none is found, compare the stop words to the next phrase in the dataset.
- Steps 3 and 4 should be repeated until the search result (Stop words) contrasts the dataset's end sentence.
- If the final sentence in the list fails to match, the Linear Search Function is halted, and the message "Sentence not found" is shown.

Algorithm 1. Linear Pursuit Algorithm
Linear Pursuit (Telugu Sentence Sen, Value b) //Sen is the name of the dataset, and b is the stop words element.
Step 1: Set $i = 0$ // i is the index of a which starts from 0
Step 2: if $i > n$, then go to step 7 // n is the number of stop words in the sentence
Step 3: if $Sen [i] = b$, then go to step 6
Step 4: Set $i = i+1$
Step 5: Go to Step 2
Step 6: Display stop word is found
Step 7: Display stop word is not found
Step 8: Terminate

Table 5. Example of Linear Pursuit Algorithm

Original Telugu Sentence	Stop words removed sentence	Polarity (1, 0, -1)
2008లో ముంబయిలోని తాజ్ హిల్ హోటల్, ఒకటి త్రికొణ్ణమై జరిగిన ముప్పురుల దాడి సందర్భంలో కూడా ఇదే విధమైన మీడియా అత్యుత్సాహం అపారనష్టం తెచ్చింది.	2008లో ముంబయిలోని తాజ్ హిల్ హోటల్, ఒకటి త్రికొణ్ణమై జరిగిన ముప్పురుల దాడి సందర్భంలో కూడా ఇదే విధమైన మీడియా అత్యుత్సాహం అపారనష్టం తెచ్చింది	-1
మీరు విడిపోదామని నిర్ణయించుకున్న పక్షంలో బ్రిటన్ మునిగిపోతుంది	మీరు విడిపోదామని నిర్ణయించుకున్న పక్షంలో బ్రిటన్ మునిగిపోతుంది	-1
వరుసగా అదే పనిచేస్తే డిడిఎస్ రంగంలోకి దిగుతుంది.	వరుసగా అదే పనిచేస్తే డిడిఎస్ రంగంలోకి దిగుతుంది	0

This study proposed an Adaptive Synthetic Sampling (ADASYN) method for learning from unbalanced data sets. The goal here is twofold: minimizing bias and learning adaptively. [Algorithm ADASYN] describes the proposed solution for the three-class (positive, negative, and neutral) classification issue.

Input: Stop words removed training dataset D_{Str} with m samples $\{x_i, y_i\}$, $i = 1, \dots, m$, where x_i is a sentence in the n -dimensional dataset X and $y_i \in Y = \{1, -1\}$ is the class identity label (positive, negative, and neutral) associated with x_i . Define m_s and m_l as the number of samples from the minority & majority classes correspondingly. Consequently, $m_s \leq m_l$ and $m_s + m_l = m$.

Process Flow:

Determine the degree of class imbalance:

$$d = m_s/m_l, \text{ Where } d \in (0, 1). \tag{1}$$

If $d < d_{th}$ then (d_{th} is a pre-determined highest allowed degree of class imbalance ratio).

- a) Determine the amount of synthetic data samples necessary for the minority class:

$$G = (m_l - m_s) \times \beta, \quad (2)$$

where $\beta \in [0, 1]$ is a parameter utilized to set the desired balance level once the synthetic data has been generated. $\beta = 1$ After the generalization process, a properly balanced data set is obtained.

b) For every sample $x_i \in \text{minority class}$, find K nearest neighbours depending on Euclidean distance in n dimensional space and estimate the proportion r_i described as:

$$r_i = \Delta_i / K, i = 1, \dots, m_s, \quad (3)$$

where Δ_i is the amount of samples in K nearest neighbours of x_i that belong to the majority class, consequently $r_i \in [0, 1]$;

c) Normalize r_i allowing to $\hat{r}_i = r_i / \sum_{i=1}^{m_s} r_i$, so that \hat{r}_i is a density distribution ($\sum_i \hat{r}_i = 1$).

d) Determine the number of synthetic data samples required for every minority sample x_i :

$$g_i = \hat{r}_i \times G. \quad (4)$$

G is the total synthetic data samples required for the minority class, as stated in Equations (2).

e) Generate g_i synthetic samples of data for every minority class data item x_i using the following stages.

Make the Loop from 1 to g_i .

Select one minority data sample at random x_{zi} , from K nearest neighbours for data x_i .

Create a synthetic data sample (s_i).

$$s_i = x_i + (x_{zi} - x_i) \times \lambda, \quad (5)$$

where $(x_{zi} - x_i)$ the n -dimensional difference is a vector, and λ is a random number: $\lambda \in [0, 1]$.

End Loop.

The basic concept behind the ADASYN method is to utilize a density distribution (\hat{r}_i) as a criterion to mechanically determine the number of synthetic samples necessary for every minority data sample. As a result, this study generates synthetic data based on data density, eliminating the

bias created by class imbalance. Hence, our dataset has negative, positive and neutral samples as 1400, 1400, and 1400. Then, for Parts of Speech (POS) tagging, this research proposed a novel Conditional Random Field with Lexicon weighting described in the following section.

POS Tagging. Part-of-speech tagging, often known as POS, provides a unique label to each token in a text to recognize its part of speech and, in certain situations, extra grammatical meanings. Text classifier algorithms then use this labelling information. For POS tagging, this research proposed a Conditional Random Field with Lexicon weighting, which is utilized to identify similar entities. These lexicons (e.g., positive and negative) are used as features to increase the models' accuracy.

A CRF is a sequence-modelling technique that recognizes entities or patterns in text, including POS tags (Table 6). This technique not only shows that attributes are connected, but it also takes into account potential implications while learning a pattern. The CRF equation is as follows: Y is the hidden state (such as a chunk of speech), and X is the observed variable (in our case, the entity or other words within it). A CRF stands for Discriminative Probabilistic Classifier. The difference between discriminative and generative mathematical structures is that discriminative models try to reflect conditional probability distributions. However, generative models do not, i.e., $P(y|x)$, and generative models try to model a joint probability distribution, i.e., $P(x,y)$. As demonstrated in Equation (6), the CRF framework may offer a conditional probability of a potential output sequence for an input sequence supplied by x .

$$p(y|x) = \frac{1}{Z(x)} \prod_{t=1}^T \exp \left\{ \sum_{k=1}^K \underbrace{F_k T_k}_{(y_t, y_{t-1}, X_t)} \right\}, \quad (6)$$

Normalization Weight Feature,

where (y_t, y_{t-1}, X_t) is utilized to represent a feature function, $(F_k T_k)$ is employed to signify the lexicon weight vector, then to close $Z(x)$ is used to represent the normalization factor. $T_k \rightarrow F_k$ is such that every term in T is mapped to a term in F with or without stemming. Following that, n-grams with the odds of particular words occurring in specific sequences might enhance auto-completion system forecasts.

Table 6. Example of POS Tagged Sentence

Telugu Sentence	English Translation	POS Tagged
ఆడిట్	Audit	NN
నిర్వహణ	Management	NN
ఆడిటర్	Auditor	NN
ఒక	A	QFNUM
కొత్త	New	JJ
చేపట్టే	Undertaking	VRB
ముందు	Before	PREP
సక్రమ	Correct	JJ
పద్ధతి	Method	NN
లో	In	PREP
కార్య	Work	JJ
ప్రణాళికను	Plan	NN
రూపొందించాలి	Should be made	VFM
.		SYM

Then, these tagged sentences are fed into the proposed Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSA-FWC) (Figure 2).

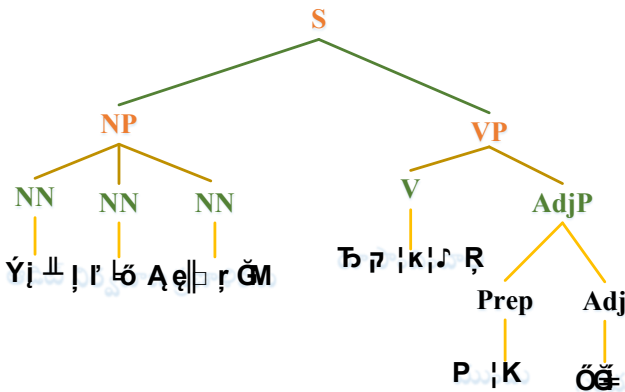


Fig. 2. Tree for POS tagged sentence

Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC). For sentiment classification, the existing research utilized regularization parameters. However, it leads to dimensionality reduction in the dataset, and it leads to error. Moreover, the loss functions are very sensitive to outliers, so there is a need to change the regularization and loss functions. Therefore, this research proposed a Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC) to overcome the limitations. In this proposed model, the membership function is evaluated based on the passive-aggressive classifier, and then, for each sample, the weights of vectors are evaluated based on the fuzzy weighting classifier. The weight vector (W_t) can be changed as the membership is introduced using this simple, efficient method.

$$W_{t+1} = W_t + \mu_t \tau_t y_t x_t, \quad (7)$$

where μ_t is the membership degree corresponding to the t -th sample, τ_t is the Lagrange multiplier, C is a positive parameter that governs how aggressive the update is, x_t and y_t is the input and target data to the t -th sample. This approach might be adapted to other online learning techniques because the membership computation remains independent of the framework update. Furthermore, such a generalized system may be used with kernelized weighing systems. The generalized Fuzzy PA technique is summarized below:

Algorithm 2. Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC)
Input: Data stream $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$, Parameter $C > 0$
Output: The vector of weights W_N
Initialization: $W_1 = (0, \dots, 0)$
For $t = 1; N - 1$
Calculate the membership μ_t of the sample x_t
Update the vector of weights, $W_{t+1} = W_t + \mu_t \tau_t y_t x_t$
End

At last, in our proposed CPSC-FWC, the Bi-direction Long Short Term Memory (Bi-LSTM) model is used to tune the hyperparameter. This table lists the layer names and the hyperparameter settings for every layer. The hypertune BiLSTM model comprises six layers in total.

In this framework, there are additional settings for the hyperparameters. Compared to the unidirectional LSTM structure, the proposed framework model is a superior option for managing huge time series sequences and preventing information loss. The hyperparameter

influences network convergence and accuracy significantly. Bi-LSTM was used to choose network hyperparameters. The variety of epochs and the learning rate are standard Bi-LSTM training hyperparameters. The network speed is modified according to weight updates (CPSC-FWC) and the learning rate (Figure 3). The learning strategy that retrains the network multiple times using the complete dataset represents the entire epochs. As a result, the network can produce more precise outcomes.




Fig. 3. Architecture for Bi-LSTM

Consequently, the proposed CPSC-FWC framework categorizes emotion as positive, negative, or neutral (Figure 4). The following section discusses the proposed model performance.




Fig. 4. Overall flowchart of the proposed approach

4. Result and Discussion. This part examines the outcomes of an experiment on the ACTSA dataset using the proposed CPSC-FWC classifier.

Tool : PYTHON 3
 OS : Windows 7 (64-bit)
 Processor : Intel Premium
 RAM : 8GB RAM

Performance Metrics and Comparison Analysis. After developing all of the techniques mentioned above, we must evaluate the effectiveness of these frameworks.

Performance Measures. The various performance metrics of the novel Machine Learning based sentiment analysis framework for Telugu text are described in this section.

Various metrics, including accuracy, F1 Score, and precision, are utilized to assess the efficacy of our proposed strategy. The proposed method's performance evaluation measures are shown in Figure 5. The results were 78% accuracy, 75% precision, and 79.9% F1 score. By implementing a unique Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC), Accuracy, F1 score, and precision are all improved by our proposed approach.




Fig. 5. Performance metrics of the proposed approach

Error Metrics of the proposed approach. The mean squared error (MSE) is used to calculate the degree of error in statistical frameworks. It is determined as the average squared variance between actual and anticipated values.

$$MSE = \frac{1}{n_z} \sum_{i=1}^{n_z} (y_{zi} - \widehat{y_{zi}})^2, \quad (8)$$

$$MAE = \frac{1}{n_z}, \quad (9)$$

where, n_z is the number of data points, y_{zi} are the observed values, $\widehat{y_{zi}}$ is the forecasted value.

Figure 6 illustrates the MSE and MAE for the proposed Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC) model. The obtained MSE and MAE values are 0.26 and 0.17, respectively, using our proposed approach.




Fig. 6. Error measures of the proposed approach

Comparison of Accuracy. The entire performance validation of a system's learning approach is completed by assessing the precision of classification according to true positive (TP), true negative (TN), false positive (FP), and false negative (FN) results. Table 7 shows the evaluation validation of accuracy for sentiment type.

$$Accuracy = \frac{TN + TP}{TN + TP + FN + FP}. \quad (10)$$

Table 7. Comparison of Accuracy

Techniques	Accuracy (%)
K means Clustering	51
Cuckoo Search Algorithm	58
Rule-based approach	70
K-Nearest Neighbour	49
Ada Boost Classifier	73
Proposed Approach	78

The overall accuracy comparison is shown in Figure 7. The accuracy of the proposed technique improves by using Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC). When compared to the baseline, the method we propose achieves greater accuracy as K means Clustering, Cuckoo Search Algorithm, Rule-based approach, K-Nearest Neighbour, and Ada Boost Classifier such as 51%, 58%, 70%, 49% and 73%. As a result, our novel technique has an accuracy of 78%, which is higher than baseline approaches.

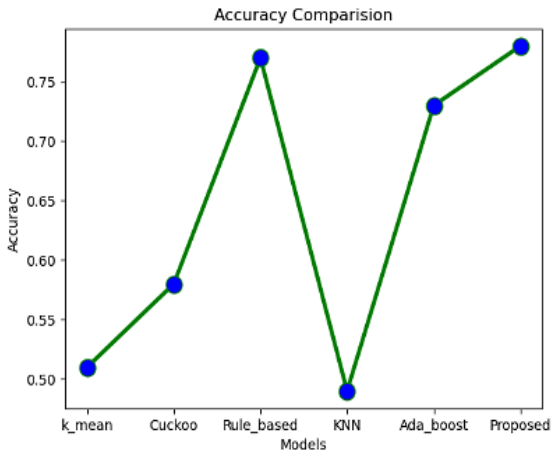


Fig. 7. Comparison of Accuracy

Comparison on Precision. The accuracy of the information processed is calculated by dividing the entire amount of sentiment sentences by the amount of precise particular sentiment predictions. Table 8 shows the precision validation evaluation for sentiment type.

$$Precision = \frac{TP}{TP + FP}. \quad (11)$$

Table 8. Comparison of Precision

Techniques	Precision (%)
K means Clustering	51
Cuckoo Search Algorithm	55
Rule-based approach	70
Ada Boost Classifier	71
Proposed Approach	75

The overall precision comparison is shown in Figure 8. The precision of the proposed technique improves by using Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC). The proposed approach attains higher precision when compared to the baseline as K means Clustering, Cuckoo Search Algorithm, Rule-based approach, and Ada Boost Classifier, which have the precision of 51%, 55%, 70%, and 71%, respectively. As a result, this novel technique has a 75 % precision higher than baseline approaches.




Fig. 8. Comparison of Precision

Comparison on F1_score. The f1_score has been verified to evaluate the mean average for accuracy and recall, allowing the f1_score to be

compared. The $f1_score$ average is produced via the average of accuracy and precision. $F1_score$ is used to test categorization accuracy. Excellent accuracy and precision result in a higher $f1_score$ rate (Table 9).

$$F1_{score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{12}$$

Table 9. Comparison of $F1_score$

Techniques	$F1_score$ (%)
K means Clustering	67.4
Cuckoo Search Algorithm	69.9
Rule-based approach	79
Ada Boost Classifier	78.6
Proposed Approach	79.9

The overall $f1_score$ comparison is shown in Figure 9.




Fig. 9. Comparison of $F1_score$

The $f1_score$ of the proposed technique improves by using Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC). The proposed approach attains a higher $f1_score$ when compared to the baseline as K means Clustering, Cuckoo Search Algorithm, Rule-based approach, and Ada Boost Classifier such as 67.4%, 69.9%, 79%, and 78.6%. As a result, the

novel technique has a precision of 79.9%, which is higher than the baseline approaches.

5. Conclusion. In this research, we developed a unique ML-based sentiment analysis framework for Telugu text. First, in the pre-processing stage, Linear Pursuit Algorithm (LPA) is proposed, which aids in removing the white spaces, punctuation, and stop words in the ACTSA Telugu dataset. Following that, we balanced the dataset by consuming our proposed Adaptive Synthetic Sampling (ADASYN) method, decreasing the bias presented by the class imbalance. Then, for POS tagging, this research proposed a Conditional Random Field with Lexicon weighting to improve the accuracy of the proposed Contrived Passive Aggressive with Fuzzy Weighting Classifier (CPSC-FWC) models. As a result, our proposed approach provides an accuracy of 78%, a precision of 75% and an *f1_score* of 79.9% when compared to the existing approach such as K means Clustering, Cuckoo Search Algorithm, Rule-based approach, and Ada Boost Classifier. The goal for years to come is to develop those classifiers so that they may adapt effectively to large-scale datasets. Consequently, DL models such as multi-layer feed-forward neural networks, CNN, RNN, and ensemble DL models have become an unavoidable avenue of future study.

References

1. Chowdhary K.R., Chowdhary K.R. Natural language processing. Fundamentals of artificial intelligence. 2020. pp. 603–649.
2. Eisenstein J. Introduction to natural language processing. MIT Press. 2019. 536 p.
3. Raina V., Krishnamurthy S., Raina V., Krishnamurthy S. Natural language processing. Building an Effective Data Science Practice: A Framework to Bootstrap and Manage a Successful Data Science Practice. 2022. pp. 63–73.
4. Nguyen H.V., Tan N., Quan N.H., Huong T.T., Phat N.H. Building a Chatbot System to Analyze Opinions of English Comments. Informatics and Automation. 2023. vol. 22, no. 2. pp. 289–315. DOI: 10.15622/ia.22.2.3.
5. Qiu X., Sun T., Xu Y., Shao Y., Dai N., Huang X. Pre-trained models for natural language processing: A survey. Science China Technological Sciences. 2020. vol. 63, no. 10. pp. 1872–1897.
6. Song L., Xin C., Lai S., Wang A., Su J., Xu K. CASA: Conversational aspect sentiment analysis for dialogue understanding. Journal of Artificial Intelligence Research. 2022. vol. 73. pp. 511–533.
7. Wang Y., Chen Q., Ahmed M.H., Chen Z., Su J., Pan W., Li Z. Supervised Gradual Machine Learning for Aspect-Term Sentiment Analysis. Transactions of the Association for Computational Linguistics. 2023. vol. 11. pp. 723–739.
8. Liu B. Sentiment analysis and opinion mining. Springer Nature, 2022. 167 p.
9. Talaat A.S. Sentiment analysis classification system using hybrid BERT models. Journal of Big Data. 2023. vol. 10, no. 1. pp. 1–18.
10. Hoang M., Bihorac O.A., Rouces J. Aspect-based sentiment analysis using Bert. Proceedings of the 22nd nordic conference on computational linguistics. 2019. 187–196.

11. Bataa E., Wu J. An investigation of transfer learning-based sentiment analysis in Japanese. arXiv preprint arXiv:1905.09642. 2019.
12. Lv H., Liu J., Wang H., Wang Y., Luo J., Liu Y. Efficient hybrid generation framework for aspect-based sentiment analysis. Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics. 2023. pp. 1007–1018.
13. Chen C., Teng Z., Wang Z., Zhang Y. Discrete opinion tree induction for aspect-based sentiment analysis. Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. 2022. vol. 1. pp. 2051–2064.
14. Esuli A., Sebastiani F. Determining the semantic orientation of terms through gloss classification. Proceedings of the 14th ACM international conference on information and knowledge management. 2005. pp. 617–624.
15. Cambria E., Havasi C., Hussain A. SenticNet 2: A semantic and affective resource for opinion mining and sentiment analysis. Proceedings of the Twenty-Fifth International Florida Artificial Intelligence Research Society Conference. 2012. pp. 202–207.
16. Xiaomei Z., Jing Y., Jianpei Z., Hongyu H. Microblog sentiment analysis with weak dependency connections. Knowledge-Based Systems. 2018. vol. 142. pp. 170–180.
17. Appel O., Chiclana F., Carter J., Fujita H. Successes and challenges in developing a hybrid approach to sentiment analysis. Applied Intelligence. 2018. vol. 48. pp. 1176–1188.
18. Yin C., Chen S., Yin Z. Clustering-based Active Learning Classification towards Data Stream. ACM Transactions on Intelligent Systems and Technology. 2023. vol. 14. no. 2. pp. 1–18.
19. Naseri S., Dalton J., Yates A., Allan J. CEQE to SQET: A study of contextualized embeddings for query expansion. Information Retrieval Journal. 2022. vol. 25. no. 2. pp. 184–208.
20. Sobkowicz P., Kaschesky M., Bouchard G. Opinion mining in social media: Modeling, simulating, and forecasting political opinions in the web. Government information quarterly. 2012. vol. 29. no. 4. pp. 470–479.
21. Hu Y.H., Chen Y.L., Chou H.L. Opinion mining from online hotel reviews—a text summarization approach. Information Processing and Management. 2017. vol. 53. no. 2. pp. 436–449.
22. Yousfi S., Rhanoui M., Mikram M. Comparative study of CNN and LSTM for opinion mining in long text. Journal of Automation, Mobile Robotics and Intelligent Systems. 2020. pp. 50–55.
23. Ethnologue Languages of the World [online]. Available at: <https://www.ethnologue.com/statistics/size> (accessed 01.09.2023).
24. Sultana J., Rani M.U., Farquod M.A.H. Knowledge discovery from recommender systems using deep learning. International Conference on Smart Systems and Inventive Technology (ICSSIT). 2019. pp. 1074–1078.
25. Sultana J., Jilani A.K. Predicting breast cancer using logistic regression and multi-class classifiers. International Journal of Engineering and Technology. 2018. vol. 7. no. 4(20). pp. 22–26.
26. Sultana J., Nagalaxmi G. How Efficient is Apriori: A Comparative Analysis. International Journal of Current Engineering and Scientific Research. 2015. pp. 2393–8374.
27. Naidu R., Bharti S.K., Babu K.S., Mohapatra R.K. Sentiment analysis using telugu sentiwordnet. International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET). 2017. pp. 666–670.
28. Garapati A., Bora N., Balla H., Sai M. SentiPhraseNet: An extended SentiWordNet approach for Telugu sentiment analysis. International Journal of Advance Research, Ideas and Innovations in Technology. 2019. vol. 5. no. 2. pp. 433–436.

29. Koppula N., Rani B.P., Srinivas Rao K. Graph-based word sense disambiguation in Telugu language. *International Journal of Knowledge-based and Intelligent Engineering Systems*. 2019. vol. 23. no. 1. pp. 55–60.
30. Sultana J. Telugu News Data Classification Using Machine Learning Approach. *Handbook of Research on Advances in Data Analytics and Complex Communication Networks*. 2022. pp. 181–194.
31. Janardana Naidu G., Seshashayee M. Sentiment analysis for Telugu text using cuckoo search algorithm. *Smart Computing Techniques and Applications: Proceedings of the Fourth International Conference on Smart Computing and Informatics*. 2021. vol. 2. pp. 253–257.
32. Suryachandra P., Venkata P., Reddy S. Machine Learning Approach to Classify the Sentiment Value of Natural Language Processing in Telugu Data. *Journal of Engineering and Applied Sciences*. 2020. vol. 15. pp. 3593–3598.
33. Tammina S. A hybrid learning approach for sentiment classification in Telugu language. *International Conference on Artificial Intelligence and Signal Processing (AISP)*. 2020. pp. 1–6.

Naidu G Janardana — Research scholar, Department of computer science, Gandhi Institute of Technology and Management GITAM (Deemed to be University). Research interests: computer science. jana.766@gmail.com; Gandhi Nagar, Rushikonda, 530045, Visakhapatnam, Andhra Pradesh, India; office phone: +91(0891)284-0501.

M Seshashayee — Ph.D., Dr.Sci., Assistant professor, Department of computer science, Gandhi Institute of Technology and Management GITAM (Deemed to be University). Research interests: computer science. mseshashayee@gmail.com; Gandhi Nagar, Rushikonda, 530045, Visakhapatnam, Andhra Pradesh, India; office phone: +91(0891)284-0501.

Д. НАЙДУ, М. СЕШАШАЯИ
**СИСТЕМА АНАЛИЗА ТОНАЛЬНОСТИ ТЕКСТА НА ТЕЛУГУ
НА ОСНОВЕ НОВОГО ПАССИВНО-АГРЕССИВНОГО
КЛАССИФИКАТОРА С НЕЧЕТКИМ ВЗВЕШИВАНИЕМ**

Найду Д., Сешашаяи М. Система анализа тональности текста на телугу на основе нового пассивно-агрессивного классификатора с нечетким взвешиванием.

Аннотация. Обработка естественного языка (NLP) – это разновидность искусственного интеллекта, демонстрирующая, как алгоритмы могут взаимодействовать с людьми на их уникальных языках. Кроме того, анализ настроений в NLP лучше проводится во многих программах, включая оценку настроений на телугу. Для обнаружения текста на телугу используются несколько неконтролируемых алгоритмов машинного обучения, таких как кластеризация k-средних с поиском с кукушкой. Однако эти методы с трудом справляются с кластеризацией данных с переменными размерами и плотностью кластеров, низкой скоростью поиска и плохой точностью сходимости. В ходе этого исследования была разработана уникальная система анализа настроений на основе машинного обучения для текста на телугу, позволяющая устранить указанные недостатки. Первоначально, на этапе предварительной обработки, предлагаемый алгоритм линейного преследования (LPA) удаляет слова в пробелах, знаках препинания и остановках. Затем для маркировки POS в этом исследовании было предложено условное случайное поле с лексическим взвешиванием; После этого предлагается надуманный пассивно-агрессивный классификатор с нечетким взвешиванием (CPSC-FWC) для классификации настроений в тексте на телугу. Следовательно, предлагаемый нами метод дает эффективные результаты с точки зрения точности, воспроизводимости и показателя f1.

Ключевые слова: машинное обучение, обработка естественного языка, полярность, анализ настроений, телугу.

Литература

1. Chowdhary K.R., Chowdhary K.R. Natural language processing. Fundamentals of artificial intelligence. 2020. pp. 603–649.
 2. Eisenstein J. Introduction to natural language processing. MIT Press. 2019. 536 p.
 3. Raina V., Krishnamurthy S., Raina V., Krishnamurthy S. Natural language processing. Building an Effective Data Science Practice: A Framework to Bootstrap and Manage a Successful Data Science Practice. 2022. pp. 63–73.
 4. Nguyen H.V., Tan N., Quan N.H., Huong T.T., Phat N.H. Building a Chatbot System to Analyze Opinions of English Comments. Informatics and Automation. 2023. vol. 22. no. 2. pp. 289–315. DOI: 10.15622/ia.22.2.3.
 5. Qiu X., Sun T., Xu Y., Shao Y., Dai N., Huang X. Pre-trained models for natural language processing: A survey. Science China Technological Sciences. 2020. vol. 63. no. 10. pp. 1872–1897.
 6. Song L., Xin C., Lai S., Wang A., Su J., Xu K. CASA: Conversational aspect sentiment analysis for dialogue understanding. Journal of Artificial Intelligence Research. 2022. vol. 73. pp. 511–533.
 7. Wang Y., Chen Q., Ahmed M.H., Chen Z., Su J., Pan W., Li Z. Supervised Gradual Machine Learning for Aspect-Term Sentiment Analysis. Transactions of the Association for Computational Linguistics. 2023. vol. 11. pp. 723–739.
 8. Liu B. Sentiment analysis and opinion mining. Springer Nature, 2022. 167 p.
- 62 Информатика и автоматизация. 2024. Том 23 № 1. ISSN 2713-3192 (печ.)
ISSN 2713-3206 (онлайн) www.ia.spcras.ru

9. Talaat A.S. Sentiment analysis classification system using hybrid BERT models. *Journal of Big Data*. 2023. vol. 10. no. 1. pp. 1–18.
10. Hoang M., Bihorac O.A., Rouces J. Aspect-based sentiment analysis using Bert. *Proceedings of the 22nd nordic conference on computational linguistics*. 2019. 187–196.
11. Bataa E., Wu J. An investigation of transfer learning-based sentiment analysis in Japanese. *arXiv preprint arXiv:1905.09642*. 2019.
12. Lv H., Liu J., Wang H., Wang Y., Luo J., Liu Y. Efficient hybrid generation framework for aspect-based sentiment analysis. *Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics*. 2023. pp. 1007–1018.
13. Chen C., Teng Z., Wang Z., Zhang Y. Discrete opinion tree induction for aspect-based sentiment analysis. *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics*. 2022. vol. 1. pp. 2051–2064.
14. Esuli A., Sebastiani F. Determining the semantic orientation of terms through gloss classification. *Proceedings of the 14th ACM international conference on information and knowledge management*. 2005. pp. 617–624.
15. Cambria E., Havasi C., Hussain A. SenticNet 2: A semantic and affective resource for opinion mining and sentiment analysis. *Proceedings of the Twenty-Fifth International Florida Artificial Intelligence Research Society Conference*. 2012. pp. 202–207.
16. Xiaomei Z., Jing Y., Jianpei Z., Hongyu H. Microblog sentiment analysis with weak dependency connections. *Knowledge-Based Systems*. 2018. vol. 142. pp. 170–180.
17. Appel O., Chiclana F., Carter J., Fujita H. Successes and challenges in developing a hybrid approach to sentiment analysis. *Applied Intelligence*. 2018. vol. 48. pp. 1176–1188.
18. Yin C., Chen S., Yin Z. Clustering-based Active Learning Classification towards Data Stream. *ACM Transactions on Intelligent Systems and Technology*. 2023. vol. 14. no. 2. pp. 1–18.
19. Naseri S., Dalton J., Yates A., Allan J. CEQE to SQET: A study of contextualized embeddings for query expansion. *Information Retrieval Journal*. 2022. vol. 25. no. 2. pp. 184–208.
20. Sobkowicz P., Kaschesky M., Bouchard G. Opinion mining in social media: Modeling, simulating, and forecasting political opinions in the web. *Government information quarterly*. 2012. vol. 29. no. 4. pp. 470–479.
21. Hu Y.H., Chen Y.L., Chou H.L. Opinion mining from online hotel reviews—a text summarization approach. *Information Processing and Management*. 2017. vol. 53. no. 2. pp. 436–449.
22. Yousfi S., Rhanoui M., Mikram M. Comparative study of CNN and LSTM for opinion mining in long text. *Journal of Automation, Mobile Robotics and Intelligent Systems*. 2020. pp. 50–55.
23. *Ethnologue Languages of the World* [online]. Available at: <https://www.ethnologue.com/statistics/size> (accessed 01.09.2023).
24. Sultana J., Rani M.U., Farquad M.A.H. Knowledge discovery from recommender systems using deep learning. *International Conference on Smart Systems and Inventive Technology (ICSSIT)*. 2019. pp. 1074–1078.
25. Sultana J., Jilani A.K. Predicting breast cancer using logistic regression and multi-class classifiers. *International Journal of Engineering and Technology*. 2018. vol. 7. no. 4(20). pp. 22–26.
26. Sultana J., Nagalaxmi G. How Efficient is Apriori: A Comparative Analysis. *International Journal of Current Engineering and Scientific Research*. 2015. pp. 2393–8374.

27. Naidu R., Bharti S.K., Babu K.S., Mohapatra R.K. Sentiment analysis using telugu sentiwordnet. International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET). 2017. pp. 666–670.
28. Garapati A., Bora N., Balla H., Sai M. SentiPhraseNet: An extended SentiWordNet approach for Telugu sentiment analysis. International Journal of Advance Research, Ideas and Innovations in Technology. 2019. vol. 5. no. 2. pp. 433–436.
29. Koppula N., Rani B.P., Srinivas Rao K. Graph-based word sense disambiguation in Telugu language. International Journal of Knowledge-based and Intelligent Engineering Systems. 2019. vol. 23. no. 1. pp. 55–60.
30. Sultana J. Telugu News Data Classification Using Machine Learning Approach. Handbook of Research on Advances in Data Analytics and Complex Communication Networks. 2022. pp. 181–194.
31. Janardana Naidu G., Seshashayee M. Sentiment analysis for Telugu text using cuckoo search algorithm. Smart Computing Techniques and Applications: Proceedings of the Fourth International Conference on Smart Computing and Informatics. 2021. vol. 2. pp. 253–257.
32. Suryachandra P., Venkata P., Reddy S. Machine Learning Approach to Classify the Sentiment Value of Natural Language Processing in Telugu Data. Journal of Engineering and Applied Sciences. 2020. vol. 15. pp. 3593–3598.
33. Tammina S. A hybrid learning approach for sentiment classification in Telugu language. International Conference on Artificial Intelligence and Signal Processing (AISP). 2020. pp. 1–6.

Найду Дж Джанардана — ученый-исследователь, факультет компьютерных наук, Институт технологий и менеджмента Ганди. Область научных интересов: информатика. jana.766@gmail.com; Ганди Нагар, Рушиконда, 530045, Вишакхапатнам, Эндра Прадеш, Индия; р.т.: +91(0891)284-0501.

Сешашаяя М — Ph.D., Dr.Sci., доцент, факультет компьютерных наук, Институт технологий и менеджмента Ганди. Область научных интересов: информатика. mseshashayee@gmail.com; Ганди Нагар, Рушиконда, 530045, Вишакхапатнам, Эндра Прадеш, Индия; р.т.: +91(0891)284-0501.

С.А. ДАВЫДЕНКО, Е.Ю. КОСТЮЧЕНКО, С.Н. НОВИКОВ
**ОЦЕНИВАНИЕ ИНФОРМАТИВНОСТИ ПРИЗНАКОВ В
НАБОРАХ ДАННЫХ ДЛЯ ПРОВЕДЕНИЯ ПРОДЛЁННОЙ
АУТЕНТИФИКАЦИИ**

Давыденко С.А., Костюченко Е.Ю., Новиков С.Н. Оценивание информативности признаков в наборах данных для проведения продлённой аутентификации.

Аннотация. Продлённая аутентификация позволяет избавиться от недостатков, присущих статической аутентификации, например, идентификаторы могут быть потеряны или забыты, пользователь совершает только первоначальный вход в систему, что может быть опасно не только для областей, требующих обеспечения высокого уровня безопасности, но и для обычного офиса. Динамическая проверка пользователя во время всего сеанса работы может повысить безопасность системы, поскольку во время работы пользователь может подвергнуться воздействию со стороны злоумышленника (например, быть атакованным) или намеренно передать ему права. В таком случае оперировать машиной будет не пользователь, который выполнил первоначальный вход. Классификация пользователей во время работы системы позволит ограничить доступ к важным данным, которые могут быть получены злоумышленником. Во время исследования были изучены методы и наборы данных, используемых для продлённой аутентификации. Затем был сделан выбор наборов данных, которые использовались в дальнейшем исследовании: данные о движении смартфона и смарт-часов (WISDM) и динамике активности мыши (Chao Shen's, DFL, Balabit). Помочь улучшить результаты работы моделей при классификации может предварительный отбор признаков, например, через оценивание их информативности. Уменьшение размерности признаков позволяет снизить требования к устройствам, которые будут использоваться при их обработке, повысить объём перебора значений параметров классификаторов при одинаковых временных затратах, тем самым потенциально повысить долю правильных ответов при классификации за счёт более полного перебора параметров значений. Для оценивания информативности использовались метод Шеннона, а также алгоритмы, встроенные в программы для анализа данных и машинного обучения (WEKA: Machine Learning Software и RapidMiner). В ходе исследования были выполнены расчёты информативности каждого признака в выбранных для исследования наборах данных, затем с помощью RapidMiner были проведены эксперименты по классификации пользователей с последовательным уменьшением количества используемых при классификации признаков с шагом в 20%. В результате была сформирована таблица с рекомендуемыми наборами признаков для каждого набора данных, а также построены графики зависимостей точности и времени работы различных моделей от количества используемых при классификации признаков.

Ключевые слова: информативность, классификация, продлённая аутентификация, машинное обучение, отбор признаков, информационная безопасность.

1. Введение. Аутентификация пользователей критически важна для компьютерных систем. В настоящее время наиболее популярные подходы к аутентификации – это методы, основанные на знании (пароли) и методы, основанные на владении (например, смарт-картой, токеном). При этом данные средства могут быть легко украдены, потеряны или забыты [1], пользователи зачастую используют простые

пароли, такие как «1234», свою фамилию или же используют один пароль для большого числа различных ресурсов. Для решения данных проблем существуют различные подходы, например биометрия [2]. Несмотря на это, всё ещё существует один критический недостаток: пользователь аутентифицируется только при первоначальном входе в систему и не аутентифицируется повторно до тех пор, пока не выйдет из системы или не пройдёт значительный интервал между его действиями на рабочей станции. Это представляет большую проблему не только для областей, в которых требуется высокая безопасность, но и в обычном офисе: ведь кто угодно может получить доступ к данным, с которыми работает пользователь, если он не вышел из системы на время перерыва. Уже установлено, что 29% атак на организации происходят по вине инсайдеров [3]. При этом сети, использующие концепцию интернета вещей для обмена информацией между устройствами (например, в «умном доме»), тоже требуют защиты от атак [4, 5, 6]. Чтобы уменьшить вероятность того, что злоумышленник сможет совершить какие-либо действия с устройства пользователя, используют продлённую аутентификацию. Под этим термином подразумевается, что личность человека, работающего на устройстве, постоянно проверяется. В настоящее время способы проведения продлённой аутентификации можно разделить на два вида: использующие поведенческие характеристики и использующие физические характеристики [7].

Исследования, направленные на изучение данной области, ставят перед собой следующие цели:

- поиск данных, при использовании которых будет достигнута высокая точность определения легитимности пользователя;
- упрощение процесса прохождения аутентификации пользователем, с сохранением точности определения.

Основной целью данной работы является сокращение времени работы моделей при решении задачи продлённой аутентификации путём поиска наиболее информативных признаков в нескольких наборах данных и изучение зависимостей доли правильных ответов при классификации пользователей и времени работы различных моделей от выбранного алгоритма и количества используемых наиболее информативных признаков. Объект исследования – процедура проведения продлённой аутентификации. Предмет исследования – изучение зависимости времени и точности работы различных моделей для классификации пользователя от количества

используемых информативных признаков для задачи продлённой аутентификации.

Основные задачи, поставленные в данном исследовании, включают в себя:

- изучение существующих методов и наборов данных для выполнения продлённой аутентификации;
- изучение существующих методов оценивания информативности признака;
- оценивание информативности признаков в выбранных наборах данных;
- изучение влияния количества используемых информативных признаков на точность и время работы различных моделей классификации.

Под информативностью в общем случае понимают совокупное количество информации, получаемое потребителем по пространственным, спектрально-энергетическим, временным и иным признакам при их восприятии и анализе [8]. Соответственно под оцениванием информативности понимается расчёт этого значения, а само это значение называется оценкой информативности.

Для измерения точности работы системы исследователи используют следующие метрики: FAR, FRR, EER [9], TPR, FPR [10], для которых можно выделить следующие ситуации: FP (false positive) – самозванец определён неверно, FN (false negative) – легитимный пользователь определён неверно, TN (true negative) – самозванец определён верно, TP (true positive) – легитимный пользователь определён верно. FAR (false acceptance rate) – показывает отношение FP к общему числу попыток нелегитимного пользователя попасть в систему, FRR (false rejection rate) – показывает отношение FN к общему числу попыток легитимного пользователя попасть в систему. На рисунке 1 показан способ расчёта метрики EER (equal error rate) – на оси абсцисс находится пороговое значение выходной метрики классификатора, а на оси ординат – значения FAR и FRR. Понимать данный график необходимо следующим образом: по мере увеличения порогового значения FAR уменьшается (при минимальном значении порога система впускает всех, в том числе всех нелегитимных пользователей, при максимальном не впускает никого), а FRR увеличивается (при минимальном значении порога система впускает всех легитимных пользователей, при максимальном не впускает никого). EER показывает в каком значении величина FAR совпадает с FRR. TPR и FPR вычисляются по формулам 1 – 2.

$$TPR = \frac{TP}{TP + FN}, \quad (1)$$

$$FPR = \frac{FP}{FP + TN}. \quad (2)$$

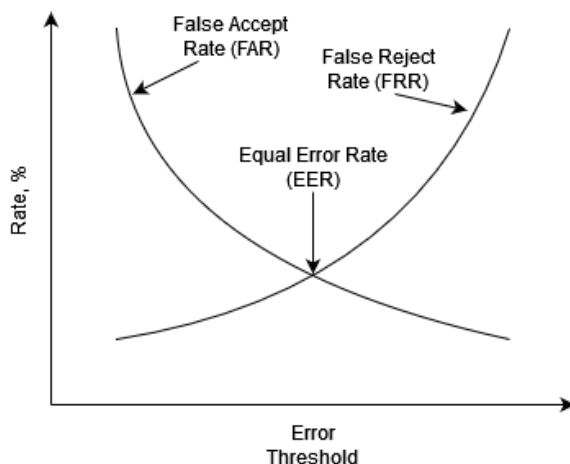


Рис. 1. Equal Error Rate

2. Подходы к выполнению продлённой аутентификации. На данный момент можно выделить следующие подходы: аутентификация по поведенческим признакам и аутентификация по физическим характеристикам, которые, в свою очередь, делятся на внешние признаки и признаки жизнедеятельности.

В статье [11] авторы рассматривают использование данных со смарт-часов пользователя для продлённой аутентификации. В плюсы они приводят то, что данные возникают естественным путём при взаимодействии с устройствами ввода (мышью, клавиатурой, сенсорным экраном), для их сбора не требуется активного вмешательства пользователя, а устройства, собирающие данные, по умолчанию оснащены необходимыми датчиками (гироскопом, акселерометром) и имеют подключение к интернету. Авторы использовали общедоступный набор данных WISDM, собранный во время использования смарт-часов и смартфонов для различных действий в течение трёх минут, но рассматривали они только активность при печатании. Всего в наборе данных содержится 90

высокоуровневых признаков, но исследователями также были проведены эксперименты, в которых использовались только 60 признаков. Авторы использовали 6 разных классификаторов и получили Avg. TP Rate в 77,3-87,2%, Avg. FP Rate в 0,2-0,5% и Avg. Precision в 78,2-87,9%, после чего пришли к следующим выводам: классификатор MLP справляется с задачей лучше всего, имея высокий TPR и низкий FPR, уменьшение признаков до 60 не сильно влияет на точность, при этом увеличивая скорость работы системы, данные акселерометра показывают более высокую точность, FPR остаётся ниже 1% в большинстве случаев, что говорит о высокой защищённости.

В статье [12] авторы тоже используют набор данных WISDM, но в этот раз исследование проводилось для всех типов деятельности, а не только печатания. Исследователи подтвердили, что поведенческие характеристики, получаемые с помощью акселерометра в телефоне или смарт-часах, хорошо справляются с задачей обеспечения продлённой аутентификации, такая система подходит для многофакторной аутентификации. При этом использованы три разных комбинации входных данных: только данные с акселерометра телефона (Ph Accel), данные с акселерометра часов и акселерометра телефона (All Accel) и данные с гироскопа и акселерометра как телефона, так и часов (All Sensors). Средняя точность идентификации пользователя при выполнении различных действий с помощью разных классификаторов составила от 59,3% (SVM по данным All Sensors) до 95,7% (Random Forest по данным Ph Accel). Расширив количество действий для классификации пользователя и используя только данные акселерометра для аутентификации, исследователи не только смогли добиться точностей выше, чем в предыдущей работе, но и расширить возможности выполнения продлённой аутентификации. При работе за компьютером человек может не только печатать, но и принимать пищу, активно шевелить руками, или просто сидеть спокойно; увеличение количества рассматриваемых активностей позволяет приблизить эксперименты по продлённой аутентификации с помощью данных со смарт-часов к реальности.

В то же время данные, получаемые с помощью мобильных устройств, предлагаются к использованию не только для продлённой аутентификации при работе за компьютером, но и при работе с самим смартфоном [13], поскольку в нём также могут содержаться очень важные данные, которые требуют защиты (например, банковские приложения). В качестве используемых данных для верификации

пользователя исследователи уже рассмотрели особенности походки пользователя [14, 15], клавиатурный почерк [14, 16, 17], данные с акселерометра [17 – 25], гироскопа [17 – 25], данные GPS [17, 21], магнитометра [17 – 20, 25], данные с сенсорного экрана [19, 24, 26], данные об использовании приложений [21, 27, 28], данные о нажатиях на экран (сила давления, место нажатия, длина нажатий) [21, 29] и датчики вращения [17]. Большое количество исследований по применению акселерометра и гироскопа различных устройств говорит о достаточно частом применении таких наборов данных, а также о том, что их получение не является нетривиальной задачей и может быть использовано не только на специфических предприятиях с высокими требованиями к безопасности, но быть доступным для обычных пользователей.

Одна из поведенческих характеристик человека при работе с компьютером – это динамика нажатия клавиш. Её плюсами является то, что для её измерения нет необходимости в использовании дополнительного оборудования, а пользователи используют клавиатуру как для работы, так и во время отдыха, поэтому у них не возникает дополнительного раздражения [30]. Подходы, использующие динамику нажатия клавиш, используются в статьях [31 – 38]. В частности, в статье [39] исследователи утверждают, что при нажатии клавиши генерируется три события: `key_up` (клавиша отпущена), `key down` (клавиша нажата), `key_press` (фактический символ вносится в текст); также они делят признаки на общие: частота появления ошибок при наборе текста (использования `backspace`, `delete`), использования клавиш управления (`ctrl`, `alt`), и общую скорость печатания; и временные: `Interval` (время между нажатием клавиш), `Dwell time` (продолжительность нажатия), а также метрики для двух последовательных нажатий клавиш: `Latency` (время между нажатием первой клавиши и моментом когда отпущена вторая), `Flight time` (время между нажатием первой клавиши и нажатием второй) и `Up to Up` (время между моментом, когда отпущена первая клавиша и когда отпущена вторая). В основе работы с динамикой нажатия клавиш лежит работа с N-граммами, в данном исследовании «схожие» N-граммы объединялись в кластеры, поиск оптимального количества кластеров (k) стоял как одна из основных задач перед авторами. При классификации входных данных X генерируется вектор вероятностей принадлежности к классам. Обычно X определяется как принадлежащий к классу с наибольшей вероятностью, но исследователи приняли решение об использовании порогового значения (P_t), малое значение P_t увеличивает FAR и уменьшает FRR,

высокое – оказывает обратный эффект. Использованный набор данных был взят из исследования, проводившегося ранее [40], при этом авторами было принято решение о вынесении вердикта не после полной сессии, а после одной, двух и трёх четвертей сессий. FAR составил от 0,3% до 0,61%, а EER от 0,15% до 0,3%.

В статье [41] автор также рассматривает динамику нажатия клавиш. Он приходит к выводу, что такие системы можно рассматривать как кейлоггер, поэтому для того, чтобы их использовать необходимо чтобы пользователь полностью доверял разработчикам системы, ведь они могут отслеживать его сообщения, пароли иные важные и секретные данные. Другая часто используемая для продлённой аутентификации поведенческая характеристика – активность мыши. Такой подход рассматривается в статьях [42 – 46]. В частности, в статье [47] авторы собрали информацию об использовании мыши студентами с конца ноября по начало декабря 2014 года. Для сбора данных о курсоре использовался встроенный в ОС Windows `GetCursorPos()` из заголовочного файла `winuser.h`, отслеживающий его положение в определённые моменты времени. Помимо данных о курсоре также собиралась информация о состоянии клавиш мыши (нажаты или нет), данные записывались каждые 15,6 мс. Всего было собрано 76500 образцов данных для 45 пользователей. Для составления профиля пользователя использовались следующие признаки: длина правого и левого клика, длина двойного левого клика, скорость, ускорение и резкость движения (изменение ускорения с течением времени). Исследователи разбили полученные данные каждого пользователя на 2 набора, один используется для того, чтобы получить профиль пользователя, другой используется для тестирования. Оценка соответствия профиля пользователя и тестовых данных – это отношение принятых системой признаков к общему числу полученных признаков. По результатам исследования авторы получили значения EER, самое низкое из которых: 6,7%, а среднее: 13,19%. Следует отметить, что под R values исследователи подразумевали пороговое значение для того, чтобы уменьшить количество шума в полученных данных, но при этом сохранить уникальность показателей, а под M values – размах диапазона в стандартных отклонениях, чем меньше M, тем сложнее успешно пройти аутентификацию.

Большое количество исследований, посвящённых динамике нажатия на клавиши и динамике движения мыши, говорит о высокой востребованности и применимости такого типа данных для продлённой аутентификации. Широкое распространение устройств,

используемых для получения информации о пользователе для составления его профиля, позволяет упростить сбор данных, а также применять модели для классификации пользователей почти на любом компьютере.

В статье [48] авторами был рассмотрен подход по использованию лингвистического стиля текста. Для своего исследования авторы использовали образцы текста из CASIS (Center for Advanced Studies in Identity Science): 4000 образцов текста от 1000 пользователей, не являющихся носителями английского языка. В каждом образце в среднем около 1600 символов, 300 слов и 13 предложений, оценивание производилось для блоков с размерами в 50 и 100 символов. Текст характеризуется признаками, происходящими из шести категорий: символьные (N-граммы), лексические (отличия на уровне слова), синтаксические (структура на уровне предложения), семантические (смысловое значение), структурные (организация документа, например отступы) и предметно-специфические. В качестве классификатора авторы используют алгоритм изоляционного леса с 50 деревьями. По графику TPR, приведённому исследователями видно, что с увеличением числа образцов TPR увеличивается, при этом уже на 5 образцах достигаются значения в 99,35% и 98,5% соответственно. Авторы делают вывод, что масштабируемость такого подхода, а также малый шанс ошибочной верификации (меньше 1%) говорят о высокой актуальности такого решения. При этом они отмечают, что такая система имеет смысл в ситуациях с одним пользователем, но может быть непрактичной, если в системе несколько участников (например, несколько авторов, работающих над одной статьёй), также масштабируемость ограничивается другими языками. Следует отметить, что TPR является не самой лучшей метрикой для измерения качества классификации, поскольку добиться 100% TPR можно путём простого трактования всех пользователей как легитимных. Для более объективной оценки статьи не хватает дополнительных метрик, показывающих иные параметры работы построенной модели. Профиль применения такого набора данных для продлённой аутентификации весьма ограничен, а данные, необходимые для построения профиля пользователя, сложны для сбора. Данные недостатки не позволяют говорить о возможности широкого использования моделей, использующих такие наборы данных.

В статье [49] авторы предлагают использовать «мягкую» биометрию (цвет одежды и цвет кожи пользователя) для выполнения

продлённой аутентификации. В плюсы данного метода выдвигается следующее: пользователю не требуется вводить никаких данных, в том числе биометрических, также нет необходимости в предварительной регистрации признаков, они регистрируются автоматически при каждом входе пользователя в систему. Ключевым отличием подхода авторов статьи от исследований, использующих схожие данные (лицо пользователя) является то, что перед системой ставится не задача идентификации пользователя, а проверка того, является ли он тем же человеком, что совершил первоначальный вход в систему. На рисунке 5 показана начальная регистрация данных пользователя, для работы с «мягкой» биометрией используются цветовые гистограммы, а для работы с лицом пользователя – каскады Хаара. При этом система учитывает изменение освещения в помещении, в такой ситуации данные сессии пользователя будут обновлены. Используя «мягкую» биометрию в дополнение к фотографии лица пользователя, авторы смогли упростить процесс продлённой аутентификации. Система показала свою работоспособность при различных действиях пользователя перед монитором. При сборе данных для модели не используются сложных устройств, многие ноутбуки оснащены веб-камерой по умолчанию поэтому применимость такого способа выполнения аутентификации достаточно высока.

В статье [50] авторы используют устройства отслеживания направления взгляда для анализа радужки глаза. По итогу исследования они получили EER в 9% и пришли к выводу, что для единственного средства аутентификации данный способ не подходит, но он может быть использован как дополнительное средство.

В статье [51] авторы предлагают использовать систему продлённой аутентификации на основе сердцебиения. Для получения данных используется доплеровский радиолокационный датчик. Плюсы данного подхода следующие: эта характеристика уникальна (различима для разных субъектов), измерима (тяжело скрыть), произвольна (неизвестна пользователю), безопасна (трудно подделать) и есть у любого живого человека. Также на её результаты не влияют шумы, которые присутствуют в методах, использующих камеру. Исследователи сообщают, что добились BAC (balanced accuracy) в 98,61% и EER в 4,42%. Авторы использовали данные 78 человек, для эксперимента выбирались люди, не обладающие сердечными заболеваниями, для каждого было собрано 20 образцов по 8-10 сердечных циклов. За признаки были взяты внутренние

геометрические дескрипторы (амплитуда, площадь, угол), полученные из реперных точек.

В статье [52] исследователи использовали электрокардиограммы для идентификации и верификации пользователя, в работе использовалось 5 открытых наборов данных и один, созданный исследователями. Данные получают с помощью сенсоров, прикрепляемых к телу человека для снятия сигнала, или с применением специального устройства, позволяющего получать данные ЭКГ без предварительной подготовки человека к снятию данных. Авторы смогли добиться 100% точности распознавания с EER, варьирующимся от 0,5% до 1,8%. Для извлечения данных об активности сердца также можно использовать фитнес-трекеры, что было продемонстрировано исследователями в статье [53]. Поскольку в статьях [50 – 52] для сбора данных о пользователе используются специальные устройства, которые не применяются при ежедневной работе за компьютером, применимость такого способа выполнения продлённой аутентификации в реальных условиях достаточно мала.

В статье [54] авторы рассматривают использование голоса для продлённой аутентификации во время выполнения звонков. Исследователи получали запись звуков через VoxGuard, в дальнейшем извлекались признаки с помощью скрытых Марковских моделей. Каждая модель представляет собой фонему, всего их было получено 41, для работы с ними использовался распознаватель фонем, который показал не очень высокую точность (около 30-50%). Верификация производится следующим образом: запись голоса делится на сегменты, затем сегмент разбивается на фонемы. Фонемы и первоначальная запись голоса передаются системе VoxGuard, она выносит оценку схожести. Такая операция выполняется для каждого сегмента записи после чего выносится общий вердикт. В итоге исследователями была получена EER в 15%. Микрофоны – достаточно широко распространённое устройство, зачастую встроенное в ноутбуки, но при этом для получения данных о голосе необходимо говорить, в то время как при ежедневной работе за компьютером пользователь, как правило, соблюдает тишину и ни с кем не разговаривает.

В статье [55] рассматривается использование паттернов дыхания для выполнения продлённой аутентификации. В плюсы приводятся следующие аргументы: не требуется каких-либо дополнительных действий от пользователя, поскольку дышит человек автоматически, данная система может быть использована

для любых устройств, работающих с Wi-Fi, например в умном доме. Wi-Fi используется во многих корпоративных и домашних сетях, поэтому применение такого подхода может быть весьма практичным, главной проблемой будет сбор данных о дыхании пользователя через данные каналы обмена информацией. Дыхание каждого человека уникально, оно содержит следующие признаки: глубину, ритм вдохов/выдохов, частоту. Для сбора данных о дыхании пользователей используется информация о состоянии канала Wi-Fi, которая позволяет получать информацию о жизнедеятельности человека [56], на основании эти данных строится профиль пользователя. Также авторы используют нейронную сеть для определения личности пользователя и собирают обратную связь от пользователей (в случае изменения паттерна дыхания, связанного, например, с болезнью).

Исследователи использовали данные 20 человек (14 мужчин и 6 женщин), для каждого из них было собрано около 200-300 образцов дыхания во время сидения на кресле на протяжении четырёх месяцев. Для оценивания использовались следующие метрики: Authentication Success Rate (процент успешной аутентификации), FPR, Spoofing Detection Rate (процент атак, которые отмечены как атака), Receiver Operating Characteristic (показывает компромисс между частотой FPR и SDR при различных пороговых значениях). В результате экспериментов были получены следующие результаты: средний ASR около 90%, SDR – 92,14% с FPR около 5%. Авторы отмечают влияние размеров обучающей выборки и скорости передачи данных на конечную точность системы.

В настоящей работе были изучены существующие подходы к проведению продлённой аутентификации для компьютеров и смартфонов, а также рассмотрены используемые исследователями входные данные для классификации. В таблице 1 приведены краткие итоги исследования.

Рассмотренные исследования не содержат информации об оценивании информативности признаков для классификации, поэтому можно предположить, что авторы не использовали этот метод для отбора признаков. Для изучения зависимости доли правильных ответов и времени работы классификаторов от количества используемых признаков, было принято решение предварительно оценить информативность каждого признака на примере наборов данных для продлённой аутентификации.

Таблица 1. Итоги исследования существующих типов данных для продлённой аутентификации

Тип данных	Устройство	Используемый канал связи
Движения во время набора текста, полученные через смартфон/смарт-часы	Смартфон/смарт-часы	Электронная почта, бухгалтерский учёт
Клавиатурный почерк	Клавиатура, смартфон	Электронная почта, бухгалтерский учёт
Динамика активности мыши	Мышь	Любая работа за ПЭВМ
Лицо	Камера	Сеансы видеосвязи
Отпечаток пальца	Сканер отпечатка пальца	Любая работа за ПЭВМ
Дыхание	Wi-Fi роутеры	Любая работа за ПЭВМ
Радужка глаза	Отслеживатель глаз, сканер радужки, камера	Любая работа за ПЭВМ
Сердечная активность	Доплеровский радиолокационный датчик, устройства для получения электрокардиограмм	Любая работа за ПЭВМ
Голос	Микрофон	Сеансы видеосвязи, голосовой связи
Мягкая биометрия	Камера	Сеансы видеосвязи
Лингвистический анализ	Специальных устройств не требуется	Электронная почта, бухгалтерский учёт
Движения при использовании мобильного устройства	Смартфон	Работа с приложениями на смартфоне
Динамика использования приложений	Смартфон	Работа с приложениями на смартфоне
Динамика использования сенсорного экрана	Мобильный телефон с сенсорным экраном	Работа с приложениями на смартфоне

2. Оценивание информативности. После изучения типов наборов данных, представленных в разделе 1, было принято решение использовать поведенческие характеристики для дальнейших исследований. Обосновано это следующими факторами: по поведенческим признакам больше исследований, а следовательно, и больше источников данных, в то время как для внешних признаков и признаков жизнедеятельности исследователи, как правило, собирают данные самостоятельно и в открытый доступ их потом не выкладывают. Следует отметить, что при поиске следует ориентироваться на следующие параметры: открытость набора данных и наличие в нём выделенных признаков. В первую очередь был выполнен поиск наборов данных, которые работают с динамикой нажатия клавиш. Исключая те

исследования, в которых авторы собирали данные самостоятельно, в основном используют следующие наборы данных:

- Clarkson University Dataset (требуется запрос) [57 – 60];
- Buffalo Dataset (требуется запрос) [58, 60, 61];
- University of Victoria (требуется запрос) [62];
- Keystroke and Mouse Dynamics for UEBA Dataset (нет признаков) [63];
- The WOLF of SUDT (требуется запрос) [64];
- BB-MAS (нет признаков) [65].

Также помимо этих наборов данных несколько исследователей упоминают об использовании в своих работах собранные ими наборы данных:

- Free vs. transcribed text for keystroke-dynamics evaluations (нет признаков) [66];
- On continuous user authentication via typing behavior (рассматривают видеозаписи набора текста) [67];
- Shared Data Set for Free-Text Keystroke Dynamics Authentication Algorithms. (нет признаков) [68];
- Identity verification through dynamic keystroke analysis (нет в открытом доступе) [40, 69];
- Keystroke patterns as prosody in digital writings: A case study with deceptive reviews and essays (нет признаков) [70];
- Shared Dataset on Natural Human-Computer Interaction to Support Continuous Authentication Research (нет в открытом доступе) [71].

Поскольку ни один из перечисленных ранее наборов данных не удовлетворяет вышеобозначенным условиям, был выполнен поиск наборов данных, осуществляющих продлённую аутентификацию с использованием активности мыши. Найдены были исследования, использующие следующие наборы данных:

- Bogazici mouse dynamics dataset (нет в открытом доступе) [46, 72];
- Chao Shen's [43, 73, 74];
- Balabit [75 – 77];
- DFL [78].

Из данного списка Balabit, DFL и Chao Shen подходят для дальнейшего исследования, поскольку они открыты и в них уже выделены признаки. Также, помимо этих наборов данных, было принято решение использовать набор данных WISDM. Этот набор данных тоже соответствует обозначенным критериям, но требует предварительной обработки, поскольку рассматривает не только

работу за компьютером, но и другие действия, которые может выполнять пользователь. Данные из WISDM [79] были обработаны следующим образом: для одного устройства (телефона или смарт-часов) выбирался один тип датчика (гироскоп или акселерометр), после чего данные всех пользователей, измеренные этими устройством и датчиком, объединялись в один файл. Затем из данного файла удалялись все активности помимо набора текста.

Для оценивания информативности [80, 81] использовались следующие средства: WEKA machine learning tool [82], RapidMiner Studio [83] и собственноручно написанная программа на языке python для расчёта информативности признака по методу Шеннона (формулы 6 – 8). Такой выбор программ для расчётов связан в первую очередь с тем, что в отличие от аналогов они предоставляют не только алгоритмы, позволяющие проводить предварительную обработку признаков перед классификацией, но и данные об информативности, рассчитанные во время этой обработки. Это позволяет выполнять сортировку признаков по данному параметру (по возрастанию или убыванию). Из рассмотренных аналогов в Orange доступен инструмент предобработки, в том числе с отбором признаков по информативности, но получить список признаков и соответствующей им информативности нельзя, а в инструменте Knime плагин InformativityGainCalculator – платный. В связи с данными ограничениями, а также с тем, что WEKA и RapidMiner бесплатны, они были выбраны в качестве основных инструментов, используемых в исследовании. При этом RapidMiner поддерживает как собственный алгоритм расчёта информативности признака, так и алгоритм из библиотеки WEKA (функция `weka.information_gain_ratio`), также это средство позволяет выполнять классификацию объектов с заданием определённых признаков, поэтому дальнейшие эксперименты, не связанные с методом Шеннона, будут выполняться в этой программе.

Для расчёта информативности признака с помощью алгоритмов WEKA используются следующие формулы:

$$I = \frac{((H(class) - H(class | attribute)))}{H(attribute)}, \quad (3)$$

$$H(x) = -\sum(P_i * \ln P_i), \quad (4)$$

где I – информативность признака, а $H(x)$ – энтропия, P – вероятность появления примера, принадлежащего к классу i .

Для расчёта $H(\text{class} | \text{attribute})$ разделим набор данных на части с одинаковыми значениями признаков (или принадлежащих одинаковым интервалам значений – для непрерывных признаков, не поддающихся прямой группировке по отдельным значениям). Для каждого значения или интервала значений признака проводим расчёт условной энтропии, а итоговую энтропию находим как сумму соответствующих условных энтропий. В RapidMiner для расчёта информативности используются схожая формула, но вместо натурального логарифма используется логарифм по основанию 2.

Метод Шеннона позволяет оценивать информативность как средневзвешенное количество информации, приходящееся на различные градации признака. Под количеством информации в теории информации понимают величину устраненной энтропии [84]. Следует отметить, что метод Шеннона даёт оценку информативности в виде нормированной величины, варьирующейся от 0 до 1. Об информативности в таком случае говорят следующее: чем $I(x)$ ближе к 1 тем выше информативность x , и наоборот, чем ближе $I(x)$ к нулю, тем информативность ниже [85]. Рассчитывается информативность признака x по следующей формуле:

$$I(x) = 1 + \sum_{i=1}^G (P_i * \sum_{k=1}^K P_{i,k} * \log_K P_{i,k}), \quad (5)$$

где G – число градаций признака, K – количество классов, P_i – вероятность попадания значения признака в i -ю градацию (формула 2), $P_{i,k}$ – вероятность появления i -ой градации признака в k -ом классе (формула 3).

Для нахождения P_i используется следующая формула:

$$P_i = \frac{\sum_{k=1}^K m_{i,k}}{N}, \quad (6)$$

где N – общее число наблюдений признака, $m_{i,k}$ – частота появления i -ой градации признака в k -ом классе.

Для нахождения $P_{i,k}$ используется следующая формула:

$$P_{i,k} = \frac{m_{i,k}}{\sum_{k=1}^K m_{i,k}}. \quad (7)$$

Пример данных об информативности признаков в наборе данных Balabit, рассчитанных с использованием трёх методов представлены в таблице 2.

Таблица 2. Сравнение информативности признаков в наборе данных Balabit

Признак	Способ расчёта		
	shannon	weka	rapid miner
a_beg_time	0,000623	0,25805	0,32903
direction_of_movement	0,00543	0,00000	0,00455
dist_end_to_end_line	0,003989	0,03265	0,22556
elapsed_time	0,001628	0,04777	0,24204
largest_deviation	0,012828	0,06026	0,25286
max_a	0,008029	0,04548	0,31813
max_curv	0,011305	0,05192	0,22556
max_jerk	0,009352	0,07502	0,31320
max_omega	0,022478	0,13271	0,27680
max_v	0,006949	0,04698	0,31320
max_vx	0,00344	0,06239	0,27384
max_vy	0,001489	0,07896	0,24204
mean_a	0,012486	0,08390	0,26115
mean_curv	0,001805	0,02117	0,22556
mean_jerk	0,007407	0,07900	0,22556
mean_omega	0,002935	0,02644	0,22556
mean_v	0,001375	0,03230	0,22556
mean_vx	0,00085	0,01892	0,26798
mean_vy	0,000339	0,01419	0,22556
min_a	0,015152	0,06077	0,25286
min_curv	0,001036	0,06454	0,22556
min_jerk	0,001937	0,08974	0,23720
min_omega	0,034644	0,12979	0,29641
min_v	0,005781	0,04389	0,25286
min_vx	0,00282	0,06531	0,31059
min_vy	0,00523	0,09105	0,22556
num_critical_points	0,004077	0,08430	0,22556
num_points	0,00206	0,07257	0,22556
sd_a	0,005084	0,04127	0,27384
sd_curv	0,001067	0,03506	0,25286
sd_jerk	0,002005	0,08441	0,27384
sd_omega	0,005857	0,07404	0,24204
sd_v	0,005983	0,04235	0,24204
sd_vx	0,001944	0,03298	0,26637
sd_vy	0,003355	0,03670	0,22556
straightness	0,00699	0,03250	0,16915
sum_of_angles	0,00332	0,14158	0,33866
traveled_distance_pixel	0,007664	0,03891	0,24204
type_of_action	0,008792	0,02382	0,02184

Для данной таблицы был проведён корреляционный анализ, который показал наличие значимой корреляции между способами оценки информативности WEKA и RapidMiner (коэффициент корреляции Спирмена 0,494 статистически значим при уровне значимости 0,01) и отсутствие статистически значимой корреляции для метода Шеннона (наибольший коэффициент корреляции Спирмена 0,241 статистически не значим при уровне значимости 0,01). Это говорит об отсутствии полной согласованности между рассматриваемыми критериями информативности и необходимости дальнейшего рассмотрения каждого из них.

3. Оценка влияния отобранных информативных признаков на качество работы системы. Следующий этап исследования – проверка зависимости доли правильных ответов при классификации и времени работы различных моделей классификации от количества используемых признаков. Для этого с помощью RapidMiner будет поочерёдно выполняться классификация с разным количеством используемых признаков: сперва будут использоваться 100%, затем 80% самых информативных, после этого 60% и так далее. Для классификации с помощью RapidMiner использовался инструмент Auto Model, он упрощает расчёты долей правильных ответов при работе разных классификаторов на определённом наборе данных, при этом происходит автоматическое разделение данных на обучающую (60%) и валидационную (40%) выборки. В процессе выполнения работы были задействованы все модели, доступные через Auto Model: Naïve Bayes, Generalized Linear Model, Logistic Regression, Fast Large Margin, Deep Learning, Decision Tree, Random Forest, Gradient Boosted Trees, Support Vector Machine. Каждый классификатор выполнял многоклассовую классификацию, рассматривая каждого пользователя как отдельный класс.

После измерения показателей моделей с разным числом признаков полученные ими данные были экспортированы и по ним были построены графики. Примеры графиков зависимости доли правильных ответов моделей от количества признаков показаны на рисунках 2 – 4.

На каждом графике указан инструмент, использованный для расчёта информативности, на оси абсцисс показано количество признаков, использованное при распознавании, а на оси ординат – итоговая доля правильных ответов для модели. Каждая линия на графике обозначает соответствующую модель и показывает зависимость доли правильных ответов при работе модели от количества наиболее информативных признаков, использованных при распознавании.

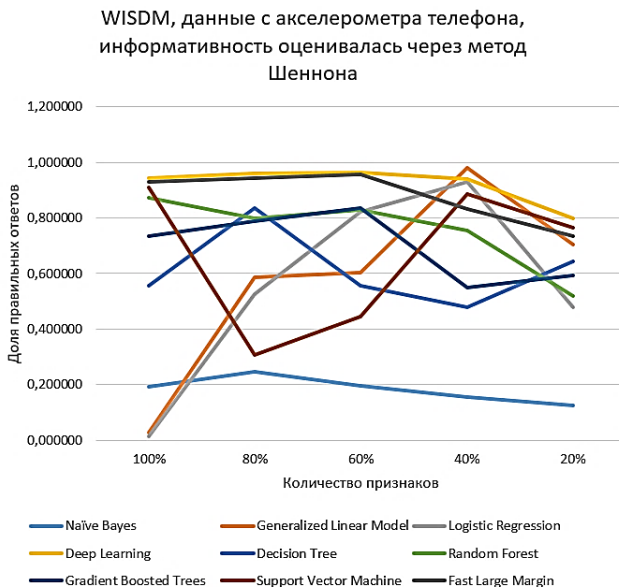


Рис. 2. Оценивание информативности через метод Шеннона, график точности




Рис. 3. Оценивание информативности через расчёты в WEKA, график точности




Рис. 4. Оценивание информативности через расчёты в RapidMiner, график точности

Примеры графиков зависимости времени работы моделей от количества признаков показаны на рисунках 5 – 7.

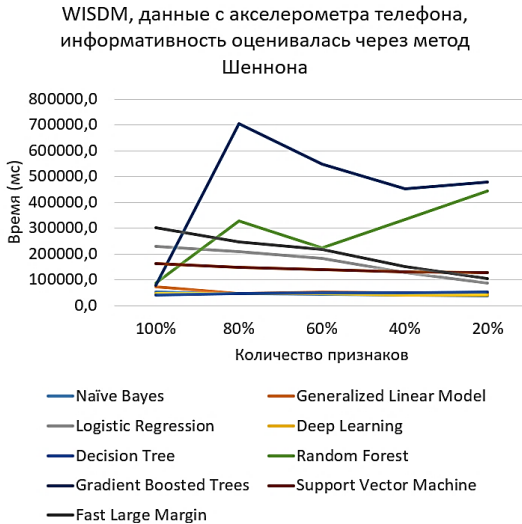


Рис. 5. Оценивание информативности через метод Шеннона, график времени обработки

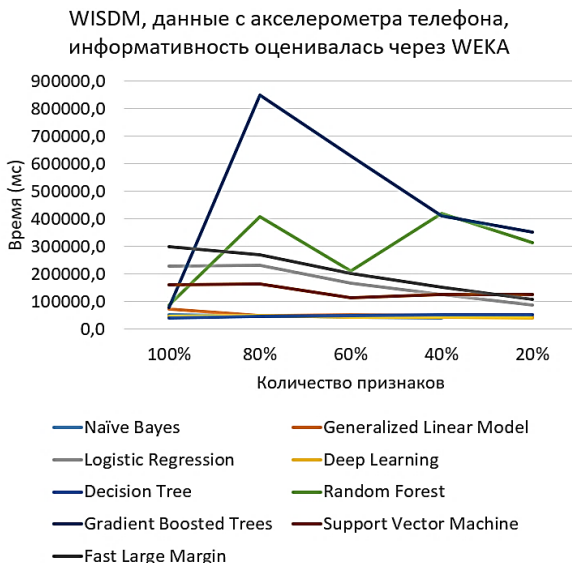


Рис. 6. Оценивание информативности через расчёты в WEKA, график времени обработки




Рис. 7. Оценивание информативности через расчёты в RapidMiner, график времени обработки

Исходя из полученных графиков, можно сделать следующие выводы:

- некоторые модели обладают стабильно высокой точностью, на которую в большинстве случаев не сильно влияет изменение количества признаков (Deep Learning, Generalized Linear Model), а некоторые, наоборот, стабильно низкой (Naive Bayes, Decision Tree);

- при уменьшении числа используемых для классификации признаков у большинства моделей уменьшается время обработки, исключением являются Gradient Boosted Trees и Random Forest при обработке признаков набора данных WISDM;

- при классификации на основе данных с акселерометра смарт часов и телефона, а также гироскопа телефона не имеет смысла отбрасывать слишком много неинформативных признаков, поскольку у большинства моделей понижается точность. Особенно это заметно при понижении с 40% признаков до 20% (рисунок 2);

- уменьшение количества признаков для наборов данных, выполняющих классификацию пользователей по активности мыши, в целом сказывается положительно и в большинстве случаев позволяет увеличить низкую изначальную точность.

Исходя из полученных в результате экспериментов данных, были выбраны наборы признаков, которые рекомендуются для достижения наибольшей точности классификации. Данные рекомендации приведены в таблице 3.

Таблица 3. Рекомендуемые наборы признаков для наборов данных

Набор данных	Рекомендуемый набор признаков
WISDM, акселерометр телефона	40% самых информативных признаков, информативность рассчитывать через метод Шеннона
WISDM, акселерометр смарт-часов	40% самых информативных признаков, информативность рассчитывать через метод Шеннона
WISDM, гироскоп телефона	80% самых информативных признаков, информативность рассчитывать через RapidMiner
WISDM, гироскоп смарт-часов	80% самых информативных признаков, информативность рассчитывать через WEKA
Balabit	80% самых информативных признаков, информативность рассчитывать через RapidMiner
Chao Shen	60% самых информативных признаков, информативность рассчитывать через метод Шеннона
DFL	20% самых информативных признаков, информативность рассчитывать через метод Шеннона

В таблице 4 приведено сравнение метрик, полученных в ходе исследования и метрик из анализируемых источников. Следует отметить, что низкие точности у наборов данных Balabit, Chao Shen и DFL могут быть связаны с тем, что в исследованиях, посвящённых им, рассматривалась бинарная классификация, при которой и были получены такие результаты, в то время как в данной работе производилась многоклассовая классификация (каждый пользователь является отдельным классом). Данный подход также применяется в исследованиях, посвящённых продлённой аутентификации как для сравнения с бинарной [86–89] так и как отдельный способ идентификации пользователя [11, 90, 91].

В [86] при использовании бинарной аутентификации средний EER составил 14,7%, в то время как при использовании многоклассовой классификации он достиг 24,9%. В [87] при использовании многоклассовой аутентификации достигли F меры в 82%, а при использовании бинарной классификации 92%. В [88] с помощью нейронной сети ANN, разработанной авторами удалось добиться максимальной точности на тестовой выборке в 92,4% на 40 классах. В [89] бинарная аутентификация показала EER на 1,01% меньше чем многоклассовая. При этом авторы отмечают, что хотя продуктивность моделей и будет выше, сбор данных для расширения моделей, использующих бинарную аутентификацию в разы сложнее чем для многоклассовой классификации, поскольку требует индивидуальной модели для каждого пользователя. В [11] при использовании многоклассового классификатора в системе с 49 пользователями, исследователи достигли TPR в 80,7-87,2% для разных типов считывающих устройств. В [90] при использовании многоклассовой аутентификации авторы достигли точности в 91,72-98%. В [91] с использованием многоклассовой классификации авторы достигли среднего значения EER в 3,96%. Рассмотренные исследования показывают, что многоклассовая аутентификация, хотя и обладает недостатками по сравнению с бинарной классификацией, может быть успешно применима для задачи продлённой аутентификации (особенно на наборе данных с малым количеством пользователей). Таким образом, использование многоклассовой классификации позволяет увеличить количество исследований, с которыми могут быть сравнены результаты работы.

Таблица 4. Сравнение метрик

Набор данных	Данные, полученные в результате данного исследования	Данные из анализируемых источников
WISDM (акселерометр телефона)	Accuracy: Random forest: 51,7-94,3% SVM: 30,6-94,6%	Accuracy: Random forest: 98,8% SVM: 94,5%
Balabit	Accuracy: Random forest: 46,12%%	Accuracy: Avg. Random forest: 72,29% [75] Avg. Random Forest: 79,7% [77]
DFL	AUC: 0.928	AUC: 0.99
Chao Shen	FAR: 70,6% FRR: 70,6%	FAR: 0,37-44,65% FRR: 1,12-34,78%

4. Заключение. В ходе проведённого исследования было выполнено оценивание информативности в доступных для исследования наборах данных для выполнения продлённой аутентификации, экспериментально были проверены зависимость точности и времени работы различных моделей для классификации пользователя от количества используемых признаков, построены графики этих зависимостей. Получены рекомендации по выбору информативных признаков, позволяющих сократить время построения и работы моделей без существенного снижения метрики качества их работы. Все задачи, поставленные в начале работы были успешно выполнены. В результате изучения построенных графиков была составлена таблица рекомендованных наборов признаков для каждого набора данных, рассмотренного в ходе исследования, а также выполнено сравнение результатов без отбора признаков и с отбором признаков с помощью оценивания информативности (таблица 4). Уменьшение количества признаков за счёт использования наиболее значимых позволит уменьшить время обучения моделей (в зависимости от алгоритма классификации и набора данных удалось сократить время работы от 5 до 82%, в среднем максимальный прирост скорости работы модели составил 40%), затраты на расширение наборов данных за счёт сокращения снимаемых признаков, а также потенциально повысить точность работы моделей при выполнении продлённой аутентификации и классификации. Перспективы дальнейшего исследования лежат в применении рассмотренных методов и инструментов для сокращения количества используемых признаков в исследованиях, также посвящённых

продлённой аутентификации для других факторов, например, аутентификации по динамике движения зрачков.

Литература

1. Jain A.K., Ross A., Pankanti S. Biometrics: a tool for information security // IEEE transactions on information forensics and security. 2006. vol. 1. no. 2. pp. 125–143.
2. Jain A.K., Ross A., Prabhakar S. An introduction to biometric recognition // IEEE Transactions on circuits and systems for video technology. 2004. vol. 14. no. 1. pp. 4–20.
3. Zhang N., Yu W., Fu X., Das S.K. Maintaining defender's reputation in anomaly detection against insider attacks // IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics). 2009. vol. 40. no. 3. pp. 597–611.
4. Liang Y., Samtani S., Guo B., Yu Z. Behavioral biometrics for continuous authentication in the internet-of-things era: An artificial intelligence perspective // IEEE Internet of Things Journal. 2020. vol. 7. no. 9. pp. 9128–9143.
5. Al-Naji F.H., Zagrouba R. CAB-IoT: Continuous authentication architecture based on Blockchain for internet of things // Journal of King Saud University-Computer and Information Sciences. 2022. vol. 34. no. 6. pp. 2497–2514.
6. Ashibani Y., Kauling D., Mahmoud Q.H. Design and implementation of a contextual-based continuous authentication framework for smart homes // Applied System Innovation. 2019. vol. 2(1). DOI: 10.3390/asi2010004.
7. Oak R. A literature survey on authentication using Behavioural biometric techniques // Intelligent Computing and Information and Communication: Proceedings of 2nd International Conference, ICICC. 2018. pp. 173–181.
8. Бондаренко М.А., Дрышкин В.Н. Оценка информативности комбинированных изображений в мультиспектральных системах технического зрения // Программные системы и вычислительные методы. 2016. Т. 1. С. 64–79.
9. Soltane M., Bakhti M. Multi-modal biometric authentications: concept issues and applications strategies // International Journal of Advanced Science and Technology. 2012. vol. 48. pp. 23–60.
10. Hong C.S., Oh T.G. TPR-TNR plot for confusion matrix // Communications for Statistical Applications and Methods. 2021. vol. 28. no. 2. pp. 161–169.
11. Rahman K.A., Alam N., Musarrat J., Madarapu A., Hossain M.S. Smartwatch Dynamics: A Novel Modality and Solution to Attacks on Cyber-behavioral Biometrics for Continuous Verification? // International Symposium on Networks, Computers and Communications (ISNCC). 2020. pp. 1–5.
12. Verma A., Moghaddam V., Anwar A. Data-driven behavioural biometrics for continuous and adaptive user verification using Smartphone and Smartwatch // Sustainability. 2022. vol. 14(12). DOI: 10.3390/su14127362.
13. Abuhamad M., Abusnaina A., Nyang D., Mohaisen D. Sensor-based continuous authentication of smartphones' users using behavioral biometrics: A contemporary survey // IEEE Internet of Things Journal. 2020. vol. 8. no. 1. pp. 65–84.
14. Lamiche I., Bin G., Jing Y., Yu Z., Hadid A. A continuous smartphone authentication method based on gait patterns and keystroke dynamics // Journal of Ambient Intelligence and Humanized Computing. 2019. vol. 10. pp. 4417–4430.
15. Giorgi G., Saracino A., Martinelli F. Using recurrent neural networks for continuous authentication through gait analysis // Pattern Recognition Letters. 2021. vol. 147. pp. 157–163.
16. Kim D.I., Lee S., Shin J.S. A new feature scoring method in keystroke dynamics-based user authentications // IEEE Access. 2020. vol. 8. pp. 27901–27914.

17. Deb D., Ross A., Jain A.K., Prakah-Asante K., Prasad K.V. Actions speak louder than (pass) words: Passive authentication of smartphone* users via deep temporal features // International conference on biometrics (ICB). 2019. pp. 1–8.
18. Abuhamad M., Abuhmed T., Mohaisen D., Nyang D. AUtoSen: Deep-learning-based implicit continuous authentication using smartphone sensors // IEEE Internet of Things Journal. 2020. vol. 7. no. 6. pp. 5008–5020.
19. Barlas Y., Basar O.E., Akan Y., Isbilen M., Alptekin G.I., Incel O.D. DAKOTA: Continuous authentication with behavioral biometrics in a mobile banking application // 5th International Conference on Computer Science and Engineering (UBMK). 2020. pp. 1–6.
20. Mekruksavanich S., Jitpattanakul A. Deep learning approaches for continuous authentication based on activity patterns using mobile sensing // Sensors. 2021. vol. 21. no. 22. DOI: 10.3390/s21227519.
21. Acien A., Morales A., Vera-Rodriguez R., Fierrez J., Tolosana R. Multilock: Mobile active authentication based on multiple biometric and behavioral patterns // 1st International Workshop on Multimodal Understanding and Learning for Embodied Applications. 2019. pp. 53–59.
22. Li Y., Hu H., Zhu Z., Zhou G. SCANet: sensor-based continuous authentication with two-stream convolutional neural networks // ACM Transactions on Sensor Networks (TOSN). 2020. vol. 16. no. 3. pp. 1–27.
23. Mekruksavanich S., Jitpattanakul A. Deep convolutional neural network with rnn for complex activity recognition using wrist-worn wearable sensor data // Electronics. 2021. vol. 10. no. 14. DOI: 10.3390/electronics10141685.
24. Volaka H.C., Alptekin G., Basar O.E., Isbilen M., Incel O.D. Towards continuous authentication on mobile phones using deep learning models // Procedia Computer Science. 2019. vol. 155. pp. 177–184.
25. Li Y., Zou B., Deng S., Zhou G. Using feature fusion strategies in continuous authentication on smartphones // IEEE Internet Computing. 2020. vol. 24. no. 2. pp. 49–56.
26. Incel O.D., Gunay S., Akan Y., Barlas Y., Basar O.E., Alptekin G.I., Isbilen M. Dakota: sensor and touch screen-based continuous authentication on a mobile banking application // IEEE Access. 2021. vol. 9. pp. 38943–38960.
27. Alotaibi S., Alruban A., Furnell S., Clarke N. A Novel Behaviour Profiling Approach to Continuous Authentication for Mobile Applications // ICISSP. 2019. pp. 246–251.
28. Mahbub U., Komulainen J., Ferreira D., Chellappa R. Continuous authentication of smartphones based on application usage // IEEE Transactions on Biometrics, Behavior, and Identity Science. 2019. vol. 1. no. 3. pp. 165–180.
29. Dee T., Richardson I., Tyagi A. Continuous transparent mobile device touchscreen soft keyboard biometric authentication // 32nd international conference on VLSI design and 18th international conference on embedded systems (VLSID). 2019. pp. 539–540.
30. Rahman K.A., Balagani K.S., Phoha V.V. Making impostor pass rates meaningless: A case of snoop-forge-replay attack on continuous cyber-behavioral verification with keystrokes // CVPR 2011 workshops. 2011. pp. 31–38.
31. Messerman A., Mustafic T., Camtepe S.A., Albayrak S. Continuous and non-intrusive identity verification in real-time environments based on free-text keystroke dynamics // International Joint Conference on Biometrics (IJCB). 2011. pp. 1–8.
32. Zack R.S., Tappert C.C., Cha S.H. Performance of a long-text-input keystroke biometric authentication system using an improved k-nearest-neighbor classification method // Fourth IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS). 2010. pp. 1–6.

33. Traore I., Woungang I., Obaidat M.S., Nakkabi Y., Lai I. Combining mouse and keystroke dynamics biometrics for risk-based authentication in web environments // Fourth international conference on digital home. 2012. pp. 138–145.
34. Quraishi S.J., Bedi S.S. On keystrokes as continuous user biometric authentication // International Journal of Engineering and Advanced Technology. 2019. vol. 8. no. 6. pp. 4149–4153.
35. Ayotte B., Huang J., Banavar M.K., Hou D., Schuckers S. Fast continuous user authentication using distance metric fusion of free-text keystroke data // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. 2019. pp. 1–9.
36. Mhenni A., Cherrier E., Rosenberger C., Amara N.E.B. Double serial adaptation mechanism for keystroke dynamics authentication based on a single password // Computers & Security. 2019. vol. 83. pp. 151–166.
37. Lu X., Zhang S., Hui P., Lio P. Continuous authentication by free-text keystroke based on CNN and RNN // Computers and Security. 2020. vol. 96. no. 101861.
38. Kiyani A.T., Lasebae A., Ali K., Rehman M.U., Haq B. Continuous user authentication featuring keystroke dynamics based on robust recurrent confidence model and ensemble learning approach // IEEE Access. 2020. vol. 8. pp. 156177–156189.
39. Shimshon T., Moskovitch R., Rokach L., Elovici Y. Continuous verification using keystroke dynamics // International conference on computational intelligence and security. IEEE Computer Society. 2010. pp. 411–415.
40. Gunetti D., Picardi C. Keystroke analysis of free text // ACM Transactions on Information and System Security (TISSEC). 2005. vol. 8. no. 3. pp. 312–347.
41. Stanic M. Continuous user verification based on behavioral biometrics using mouse dynamics // Proceedings of the ITI 2013 35th International Conference on Information Technology Interfaces. IEEE, 2013. C. 251–256.
42. Feher C., Elovici Y., Moskovitch R., Rokach L., Schelar A. User identity verification via mouse dynamics // Information Sciences. 2012. vol. 201. pp. 19–36.
43. Shen C., Cai Z., Guan X., Du Y., Maxion R.A. User authentication through mouse dynamics // IEEE Transactions on Information Forensics and Security. 2012. vol. 8. no. 1. pp. 16–30.
44. Zheng N., Paloski A., Wang H. An efficient user verification system using angle-based mouse movement biometrics // ACM Transactions on Information and System Security (TISSEC). 2016. vol. 18. no. 3. pp. 1–27.
45. Ahmed A.A.E., Traore I. A new biometric technology based on mouse dynamics // IEEE Transactions on dependable and secure computing. 2007. vol. 4. no. 3. pp. 165–179.
46. Siddiqui N., Dave R., Vanamala M., Seliya N. Machine and deep learning applications to mouse dynamics for continuous user authentication // Machine Learning and Knowledge Extraction. 2022. vol. 4. no. 2. pp. 502–518.
47. Rahman K.A., Moormann R., Dierich D., Hossain M.S. Continuous User Verification via Mouse Activities. Multimedia Communications, Services and Security: 8th International Conference, MCSS. 2015. pp. 170–181.
48. Neal T., Sundararajan K., Woodard D. Exploiting linguistic style as a cognitive biometric for continuous verification // International Conference on Biometrics (ICB). IEEE, 2018. C. 270–276.
49. Niinuma K., Park U., Jain A.K. Soft biometric traits for continuous user authentication // IEEE Transactions on information forensics and security. 2010. vol. 5. no. 4. pp. 771–780.

50. Mock K., Hoanca B., Weaver J., Milton M. Real-time continuous iris recognition for authentication using an eye tracker // Proceedings of the 2012 ACM conference on Computer and communications security. 2012. pp. 1007–1009.
51. Lin F., Song C., Zhuang Y., Xu W., Li C., Ren K.. Cardiac scan: A non-contact and continuous heart-based user authentication system // Proceedings of the 23rd Annual International Conference on Mobile Computing and Networking. 2017. pp. 315–328.
52. Ingale M., Cordeiro R., Thentu S., Park Y., Karimian N. Ecg biometric authentication: A comparative analysis // IEEE Access. 2020. vol. 8. pp. 117853–117866.
53. Ekiz D., Can Y.S., Dardagan Y.C., Ersoy C. Can a smartband be used for continuous implicit authentication in real life // IEEE Access. 2020. vol. 8. pp. 59402–59411.
54. Kunz M., Kasper K., Reininger H., Mobius M., Ohms J. Continuous speaker verification in realtime // BIOSIG 2011–Proceedings of the Biometrics Special Interest Group. 2011. pp. 79–87.
55. Liu J., Chen Y., Dong Y., Wang Y., Zhao T., Yao Y.-Do. Continuous User Verification via Respiratory Biometrics. IEEE INFOCOM 2020 – IEEE Conference on Computer Communications. 2020. pp. 1–10.
56. Zhuravchak A., Kapshii O., Pournaras E. Human Activity Recognition based on Wi-Fi CSI Data–A Deep Neural Network Approach // Procedia Computer Science. 2022. vol. 198. pp. 59–66.
57. Ceker H., Upadhyaya S. User authentication with keystroke dynamics in long-text data // IEEE 8th International Conference on Biometrics Theory, Applications and Systems (BTAS). IEEE, 2016. pp. 1–6.
58. Wang X., Shi Y., Zheng K., Zhang Y., Hong W., Cao S. User Authentication Method Based on Keystroke Dynamics and Mouse Dynamics with Scene-Irrelated Features in Hybrid Scenes // Sensors. 2022. vol. 22. no. 17. pp. 6627.
59. Vural E., Huang J., Hou D., Schuckers S. Shared research dataset to support development of keystroke authentication // IEEE International joint conference on biometrics. IEEE, 2014. pp. 1–8.
60. Li J., Chang H.C., Stamp M. Free-text keystroke dynamics for user authentication // Artificial Intelligence for Cybersecurity. Cham: Springer International Publishing, 2022. pp. 357–380.
61. Sun Y., Ceker H., Upadhyaya S. Shared keystroke dataset for continuous authentication // IEEE International Workshop on Information Forensics and Security (WIFS). IEEE, 2016. pp. 1–6.
62. Ahmed A.A., Traore I. Biometric recognition based on free-text keystroke dynamics // IEEE transactions on cybernetics. 2013. vol. 44. no. 4. pp. 458–472.
63. Martin A.G., de Diego I.M., Fernandez-Isabel A., Beltran M., Fernandez R.R. Combining user behavioural information at the feature level to enhance continuous authentication systems // Knowledge-Based Systems. 2022. vol. 244. no. 108544. DOI: 10.1016/j.knosys.2022.108544.
64. Harilal A., Toffalini F., Castellanos J., Guarnizo J., Homoliak I., Ochoa M.. Twos: A dataset of malicious insider threat behavior based on a gamified competition // Proceedings of the International Workshop on Managing Insider Security Threats. 2017. pp. 45–56.
65. Belman A.K. et al. Insights from BB-MAS--A Large Dataset for Typing, Gait and Swipes of the Same Person on Desktop, Tablet and Phone // arXiv preprint arXiv:1912.02736. 2019. 2019.
66. Killourhy K.S., Maxion R.A. Free vs. transcribed text for keystroke-dynamics evaluations // Proceedings of the Workshop on Learning from Authoritative Security Experiment Results. 2012. pp. 1–8.

67. Roth J., Liu X., Metaxas D. On continuous user authentication via typing behavior // *IEEE Transactions on Image Processing*. 2014. vol. 23. no. 10. pp. 4611–4624.
68. Iapa A.C., Cretu V.I. Shared Data Set for Free-Text Keystroke Dynamics Authentication Algorithms. 2021. DOI: 10.20944/preprints202105.0255.v1.
69. Bergadano F., Gunetti D., Picardi C. Identity verification through dynamic keystroke analysis // *Intelligent Data Analysis*. 2003. vol. 7. no. 5. pp. 469–496.
70. Banerjee R., Feng S., Kang J.S., Choi Y. Keystroke patterns as prosody in digital writings: A case study with deceptive reviews and essays // *Proceedings of the Conference on empirical methods in natural language processing (EMNLP)*. 2014. pp. 1469–1473.
71. Murphy C., Huang J., Hou D., Schuckers S. Shared dataset on natural human-computer interaction to support continuous authentication research // *IEEE International Joint Conference on Biometrics (IJCB)*. IEEE, 2017. pp. 525–530.
72. Kilic A.A., Yildirim M., Anarim E. Bogazici mouse dynamics dataset // *Data in Brief*. 2021. vol. 36. no. 107094.
73. Shen C., Cai Z., Guan X. Continuous authentication for mouse dynamics: A pattern-growth approach // *IEEE/IFIP International Conference on Dependable Systems and Networks (DSN 2012)*. IEEE, 2012. pp. 1–12.
74. Shen C., Cai Z., Guan X., Maxion R. Performance evaluation of anomaly-detection algorithms for mouse dynamics // *Computers and security*. 2014. vol. 45. pp. 156–171.
75. Antal M., Egyed-Zsigmond E. Intrusion detection using mouse dynamics // *IET Biometrics*. 2019. vol. 8. no. 5. pp. 285–294.
76. Fulop A., Kovacs L., Kurics T., Windhager-Pokol E. Balabit Mouse Dynamics Challenge data set. 2017. Available at: <https://github.com/balabit/Mouse-Dynamics-Challenge> (accessed: 16.10.2023).
77. Almalki S., Chatterjee P., Roy K. Continuous authentication using mouse clickstream data analysis // *Security, Privacy, and Anonymity in Computation, Communication, and Storage: SpaCCS Proceedings 12*. Springer International Publishing, 2019. pp. 76–85.
78. Antal M., Denes-Fazakas L. User verification based on mouse dynamics: a comparison of public data sets // *IEEE 13th International Symposium on Applied Computational Intelligence and Informatics (SACI)*. IEEE, 2019. pp. 143–148.
79. Weiss G.M. Wisdm smartphone and smartwatch activity and biometrics dataset // *UCI Machine Learning Repository: WISDM Smartphone and Smartwatch Activity and Biometrics Dataset Data Set*. 2019. vol. 7. pp. 133190–133202.
80. Матвеев Ю.Н. Исследование информативности признаков речи для систем автоматической идентификации дикторов // *Известия высших учебных заведений. Приборостроение*. 2013. Т. 56. № 2. С. 47–51.
81. Стародубов Д.Н. Методика определения информативности признаков объектов // *Алгоритмы, методы и системы обработки данных*. 2008. № 13. С. 140–146.
82. Frank E., Hall M., Holmes G., Kirkby R., Pfahringer B., Witten I.H., Trigg L. Weka-a machine learning workbench for data mining // *Data mining and knowledge discovery handbook*. 2010. pp. 1269–1277.
83. Sharma P., Singh D., Singh A. Classification algorithms on a large continuous random dataset using rapid miner tool // *2nd International Conference on Electronics and Communication Systems (ICECS)*. IEEE, 2015. pp. 704–709.
84. Жигулин П.В., Мальцев А.В., Мельников М.А., Подворчан Д.Э. Анализ сетевого трафика на основе нейронных сетей // *Электронные средства и системы управления. Материалы докладов Международной научно-практической конференции*. 2013. № 2. С. 44–48.

85. Быкова В.В., Катаева А.В. Методы и средства анализа информативности признаков при обработке медицинских данных // Программные продукты и системы. 2016. № 2(114). С. 172–178.
86. Burton A, Parikh T., Mascarenhas S., Zhang J., Voris J., Artan N.S., Li W. Driver identification and authentication with active behavior modeling // 12th International Conference on Network and Service Management (CNSM). IEEE, 2016. pp. 388–393.
87. Milton L.C., Memon A. Intruder detector: A continuous authentication tool to model user behavior // IEEE Conference on Intelligence and Security Informatics (ISI). IEEE, 2016. pp. 286–291.
88. Siddiqui N., Dave R., Vanamala M., Seliya N. Machine and deep learning applications to mouse dynamics for continuous user authentication // Machine Learning and Knowledge Extraction. 2022. vol. 4. no. 2. pp. 502–518.
89. Feher C., Elovici Y., Moskovitch R., Rokach L., Schelar A. User identity verification via mouse dynamics // Information Sciences. 2012. vol. 201. pp. 19–36.
90. Kuzminykh I., Mathur S., Ghita B. Performance Analysis of Free Text Keystroke Authentication using XGBoost // Proc. of 6th International Conference on Computer Science, Engineering and Education Applications. (ICCSEEA). 2023. pp. 429–439.
91. Agrafioti F., Bui F.M., Hatzinakos D. Secure telemedicine: Biometrics for remote and continuous patient verification // Journal of Computer Networks and Communications. 2012. vol. 2012. DOI: 10.1155/2012/924791.

Давыденко Сергей Андреевич — младший научный сотрудник, центр компетенций Национальной технологической инициативы «технологии доверенного взаимодействия», Федеральное государственное бюджетное образовательное учреждение высшего образования «Томский государственный университет систем управления и радиоэлектроники». Область научных интересов: искусственный интеллект и машинное обучение. Число научных публикаций — 122. sergun_dav@mail.ru; проспект Ленина, 40, 634050, Томск, Россия; р.т.: +7(3822)51-3262.

Костюченко Евгений Юрьевич — канд. техн. наук, доцент, заведующий лабораторией, лаборатория съема, анализа и управления биологическими сигналами; доцент кафедры, кафедра комплексной информационной безопасности электронно-вычислительных систем, Федеральное государственное бюджетное образовательное учреждение высшего образования «Томский государственный университет систем управления и радиоэлектроники». Область научных интересов: искусственный интеллект и машинное обучение, обработка речи, биометрия, анализ данных. Число научных публикаций — 145. key@fb.tusur.ru; проспект Ленина, 40, 634050, Томск, Россия; р.т.: +7(3822)70-1529.

Новиков Сергей Николаевич — д-р техн. наук, доцент, заведующий кафедрой, кафедра безопасности и управления в телекоммуникациях, Сибирский государственный университет телекоммуникаций и информатики. Область научных интересов: искусственный интеллект и машинное обучение. Число научных публикаций — 122. snovikov@ngs.ru; улица Кирова, 86, 630102, Новосибирск, Россия; р.т.: +7(3832)69-2245.

Поддержка исследований. Работа выполнена при финансовой поддержке Министерства науки и высшего образования РФ в рамках базовой части государственного задания ТУСУРа на 2023–2025 гг. (проект № FEWM-2023-0015).

S. DAVYDENKO, E. KOSTYUCHENKO, S. NOVIKOV
**EVALUATION OF THE INFORMATIVENESS OF FEATURES IN
DATASETS FOR CONTINUOUS VERIFICATION**

Davydenko S., Kostyuchenko E., Novikov S. Evaluation of the Informativeness of Features in Datasets for Continuous Verification.

Abstract. Continuous verification eliminates the flaws of existing static authentication, e.g. identifiers can be lost or forgotten, and the user logs in the system only once, which may be dangerous not only for areas requiring a high level of security but also for a regular office. Checking the user dynamically during the whole session of work can improve the security of the system, since while working with the system, the user may be exposed to an attacker (to be assaulted for example) or intentionally transfer rights to him. In this case, the machine will not be operated by the user who performed the initial login. Classifying users continuously will limit access to sensitive data that can be obtained by an attacker. During the study, the methods and datasets used for continuous verification were checked, then some datasets were chosen, which were used in further research: smartphone and smart watch movement data (WISDM) and mouse activity (Chao Shen's, DFL, Balabit). In order to improve the performance of models in the classification task it is necessary to perform a preliminary selection of features, to evaluate their informativeness. Reducing the number of features makes it possible to reduce the requirements for devices that will be used for their processing, and to increase the volume of enumeration of classifier parameter values at the same time, thereby potentially increasing the proportion of correct answers during classification due to a more complete enumeration of value parameters. For the informativeness evaluation, the Shannon method was used, as well as the algorithms built into programs for data analysis and machine learning (WEKA: Machine Learning Software and RapidMiner). In the course of the study, the informativeness of each feature in the selected datasets was evaluated, and then users were classified with RapidMiner. The used in classifying features selection was decreased gradually with a 20% step. As a result, a table was formed with recommended sets of features for each dataset, as well as dependency graphs of the accuracy and operating time of various models.

Keywords: informativeness, classification, continuous verification, machine learning, feature selection, information security.

References

1. Jain A.K., Ross A., Pankanti S. Biometrics: a tool for information security. IEEE transactions on information forensics and security. 2006. vol. 1. no. 2. pp. 125–143.
2. Jain A.K., Ross A., Prabhakar S. An introduction to biometric recognition. IEEE Transactions on circuits and systems for video technology. 2004. vol. 14. no. 1. pp. 4–20.
3. Zhang N., Yu W., Fu X., Das S.K. Maintaining defender's reputation in anomaly detection against insider attacks. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics). 2009. vol. 40. no. 3. pp. 597–611.
4. Liang Y., Samtani S., Guo B., Yu Z. Behavioral biometrics for continuous authentication in the internet-of-things era: An artificial intelligence perspective. IEEE Internet of Things Journal. 2020. vol. 7. no. 9. pp. 9128–9143.
5. Al-Naji F.H., Zagrouba R. CAB-IoT: Continuous authentication architecture based on Blockchain for internet of things. Journal of King Saud University-Computer and Information Sciences. 2022. vol. 34. no. 6. pp. 2497–2514.

6. Ashibani Y., Kauling D., Mahmoud Q.H. Design and implementation of a contextual-based continuous authentication framework for smart homes. *Applied System Innovation*. 2019. vol. 2(1). DOI: 10.3390/asi2010004.
7. Oak R. A literature survey on authentication using Behavioural biometric techniques. *Intelligent Computing and Information and Communication: Proceedings of 2nd International Conference, ICICC*. 2018. pp. 173–181.
8. Bondarenko M.A., Drynkin V.N. [Evaluation of the informativeness of combined images in multispectral complex technical studies]. *Programmnye sistemy i vychislitel'nye metody – Software systems and computational methods*. 2016. vol. 1. pp. 64–79. (In Russ.).
9. Soltane M., Bakhti M. Multi-modal biometric authentications: concept issues and applications strategies. *International Journal of Advanced Science and Technology*. 2012. vol. 48. pp. 23–60.
10. Hong C.S., Oh T.G. TPR-TNR plot for confusion matrix. *Communications for Statistical Applications and Methods*. 2021. vol. 28. no. 2. pp. 161–169.
11. Rahman K.A., Alam N., Musarrat J., Madarapu A., Hossain M.S. Smartwatch Dynamics: A Novel Modality and Solution to Attacks on Cyber-behavioral Biometrics for Continuous Verification?. *International Symposium on Networks, Computers and Communications (ISNCC)*. 2020. pp. 1–5.
12. Verma A., Moghaddam V., Anwar A. Data-driven behavioural biometrics for continuous and adaptive user verification using Smartphone and Smartwatch. *Sustainability*. 2022. vol. 14(12). DOI: 10.3390/su14127362.
13. Abuhamad M., Abusnaina A., Nyang D., Mohaisen D. Sensor-based continuous authentication of smartphones' users using behavioral biometrics: A contemporary survey. *IEEE Internet of Things Journal*. 2020. vol. 8. no. 1. pp. 65–84.
14. Lamiche I., Bin G., Jing Y., Yu Z., Hadid A. A continuous smartphone authentication method based on gait patterns and keystroke dynamics. *Journal of Ambient Intelligence and Humanized Computing*. 2019. vol. 10. pp. 4417–4430.
15. Giorgi G., Saracino A., Martinelli F. Using recurrent neural networks for continuous authentication through gait analysis. *Pattern Recognition Letters*. 2021. vol. 147. pp. 157–163.
16. Kim D.I., Lee S., Shin J.S. A new feature scoring method in keystroke dynamics-based user authentications. *IEEE Access*. 2020. vol. 8. pp. 27901–27914.
17. Deb D., Ross A., Jain A.K., Prakah-Asante K., Prasad K.V. Actions speak louder than (pass) words: Passive authentication of smartphone* users via deep temporal features. *International conference on biometrics (ICB)*. 2019. pp. 1–8.
18. Abuhamad M., Abuhmed T., Mohaisen D., Nyang D. AUToSen: Deep-learning-based implicit continuous authentication using smartphone sensors. *IEEE Internet of Things Journal*. 2020. vol. 7. no. 6. pp. 5008–5020.
19. Barlas Y., Basar O.E., Akan Y., Isbilen M., Alptekin G.I., Incel O.D. DAKOTA: Continuous authentication with behavioral biometrics in a mobile banking application. *5th International Conference on Computer Science and Engineering (UBMK)*. 2020. pp. 1–6.
20. Mekruksavanich S., Jitpattanakul A. Deep learning approaches for continuous authentication based on activity patterns using mobile sensing. *Sensors*. 2021. vol. 21. no. 22. DOI: 10.3390/s21227519.
21. Acien A., Morales A., Vera-Rodriguez R., Fierrez J., Tolosana R.. Multilock: Mobile active authentication based on multiple biometric and behavioral patterns. *1st International Workshop on Multimodal Understanding and Learning for Embodied Applications*. 2019. pp. 53–59.

22. Li Y., Hu H., Zhu Z., Zhou G. SCANet: sensor-based continuous authentication with two-stream convolutional neural networks. *ACM Transactions on Sensor Networks (TOSN)*. 2020. vol. 16. no. 3. pp. 1–27.
23. Mekruksavanich S., Jitpattanakul A. Deep convolutional neural network with rnns for complex activity recognition using wrist-worn wearable sensor data. *Electronics*. 2021. vol. 10. no. 14. DOI: 10.3390/electronics10141685.
24. Volaka H.C., Alptekin G., Basar O.E., Isbilen M., Incel O.D. Towards continuous authentication on mobile phones using deep learning models. *Procedia Computer Science*. 2019. vol. 155. pp. 177–184.
25. Li Y., Zou B., Deng S., Zhou G. Using feature fusion strategies in continuous authentication on smartphones. *IEEE Internet Computing*. 2020. vol. 24. no. 2. pp. 49–56.
26. Incel O.D., Gunay S., Akan Y., Barlas Y., Basar O.E., Alptekin G.I., Isbilen M. Dakota: sensor and touch screen-based continuous authentication on a mobile banking application. *IEEE Access*. 2021. vol. 9. pp. 38943–38960.
27. Alotaibi S., Alruban A., Furnell S., Clarke N. A Novel Behaviour Profiling Approach to Continuous Authentication for Mobile Applications. *ICISSP*. 2019. pp. 246–251.
28. Mahbub U., Komulainen J., Ferreira D., Chellappa R. Continuous authentication of smartphones based on application usage. *IEEE Transactions on Biometrics, Behavior, and Identity Science*. 2019. vol. 1. no. 3. pp. 165–180.
29. Dee T., Richardson I., Tyagi A. Continuous transparent mobile device touchscreen soft keyboard biometric authentication. *32nd international conference on VLSI design and 18th international conference on embedded systems (VLSID)*. 2019. pp. 539–540.
30. Rahman K.A., Balagani K.S., Phoha V.V. Making impostor pass rates meaningless: A case of snoop-forge-replay attack on continuous cyber-behavioral verification with keystrokes. *CVPR 2011 workshops*. 2011. pp. 31–38.
31. Messerman A., Mustafic T., Camtepe S.A., Albayrak S. Continuous and non-intrusive identity verification in real-time environments based on free-text keystroke dynamics. *International Joint Conference on Biometrics (IJCB)*. 2011. pp. 1–8.
32. Zack R.S., Tappert C.C., Cha S.H. Performance of a long-text-input keystroke biometric authentication system using an improved k-nearest-neighbor classification method. *Fourth IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS)*. 2010. pp. 1–6.
33. Traore I., Woungang I., Obaidat M.S., Nakkabi Y., Lai I. Combining mouse and keystroke dynamics biometrics for risk-based authentication in web environments. *Fourth international conference on digital home*. 2012. pp. 138–145.
34. Quraishi S.J., Bedi S.S. On keystrokes as continuous user biometric authentication. *International Journal of Engineering and Advanced Technology*. 2019. vol. 8. no. 6. pp. 4149–4153.
35. Ayotte B., Huang J., Banavar M.K., Hou D., Schuckers S. Fast continuous user authentication using distance metric fusion of free-text keystroke data. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2019. pp. 1–9.
36. Mhenni A., Cherrier E., Rosenberger C., Amara N.E.B. Double serial adaptation mechanism for keystroke dynamics authentication based on a single password. *Computers & Security*. 2019. vol. 83. pp. 151–166.
37. Lu X., Zhang S., Hui P., Lio P. Continuous authentication by free-text keystroke based on CNN and RNN. *Computers and Security*. 2020. vol. 96. no. 101861.
38. Kiyani A.T., Lasebae A., Ali K., Rehman M.U., Haq B. Continuous user authentication featuring keystroke dynamics based on robust recurrent confidence model and ensemble learning approach. *IEEE Access*. 2020. vol. 8. pp. 156177–156189.

39. Shimshon T., Moskovitch R., Rokach L., Elovici Y. Continuous verification using keystroke dynamics. International conference on computational intelligence and security. IEEE Computer Society. 2010. pp. 411–415.
40. Gunetti D., Picardi C. Keystroke analysis of free text. ACM Transactions on Information and System Security (TISSEC). 2005. vol. 8. no. 3. pp. 312–347.
41. Stanic M. Continuous user verification based on behavioral biometrics using mouse dynamics. Proceedings of the ITI 2013 35th International Conference on Information Technology Interfaces. IEEE, 2013. C. 251–256.
42. Feher C., Elovici Y., Moskovitch R., Rokach L., Schclar A. User identity verification via mouse dynamics. Information Sciences. 2012. vol. 201. pp. 19–36.
43. Shen C., Cai Z., Guan X., Du Y., Maxion R.A. User authentication through mouse dynamics. IEEE Transactions on Information Forensics and Security. 2012. vol. 8. no. 1. pp. 16–30.
44. Zheng N., Paloski A., Wang H. An efficient user verification system using angle-based mouse movement biometrics. ACM Transactions on Information and System Security (TISSEC). 2016. vol. 18. no. 3. pp. 1–27.
45. Ahmed A.A.E., Traore I. A new biometric technology based on mouse dynamics. IEEE Transactions on dependable and secure computing. 2007. vol. 4. no. 3. pp. 165–179.
46. Siddiqui N., Dave R., Vanamala M., Seliya N. Machine and deep learning applications to mouse dynamics for continuous user authentication. Machine Learning and Knowledge Extraction. 2022. vol. 4. no. 2. pp. 502–518.
47. Rahman K.A., Moormann R., Dierich D., Hossain M.S. Continuous User Verification via Mouse Activities. Multimedia Communications, Services and Security: 8th International Conference, MCSS. 2015. pp. 170–181.
48. Neal T., Sundararajan K., Woodard D. Exploiting linguistic style as a cognitive biometric for continuous verification. International Conference on Biometrics (ICB). IEEE, 2018. C. 270–276.
49. Niinuma K., Park U., Jain A.K. Soft biometric traits for continuous user authentication. IEEE Transactions on information forensics and security. 2010. vol. 5. no. 4. pp. 771–780.
50. Mock K., Hoanca B., Weaver J., Milton M. Real-time continuous iris recognition for authentication using an eye tracker. Proceedings of the 2012 ACM conference on Computer and communications security. 2012. pp. 1007–1009.
51. Lin F., Song C., Zhuang Y., Xu W., Li C., Ren K. Cardiac scan: A non-contact and continuous heart-based user authentication system. Proceedings of the 23rd Annual International Conference on Mobile Computing and Networking. 2017. pp. 315–328.
52. Ingale M., Cordeiro R., Thentu S., Park Y., Karimian N. Ecg biometric authentication: A comparative analysis. IEEE Access. 2020. vol. 8. pp. 117853–117866.
53. Ekiz D., Can Y.S., Dardagan Y.C., Ersoy C. Can a smartband be used for continuous implicit authentication in real life. IEEE Access. 2020. vol. 8. pp. 59402–59411.
54. Kunz M., Kasper K., Reininger H., Mobius M., Ohms J. Continuous speaker verification in realtime. BIOSIG 2011–Proceedings of the Biometrics Special Interest Group. 2011. pp. 79–87.
55. Liu J., Chen Y., Dong Y., Wang Y., Zhao T., Yao Y.-Do. Continuous User Verification via Respiratory Biometrics. IEEE INFOCOM 2020 – IEEE Conference on Computer Communications. 2020. pp. 1–10.
56. Zhuravchak A., Kapshii O., Pournaras E. Human Activity Recognition based on Wi-Fi CSI Data-A Deep Neural Network Approach. Procedia Computer Science. 2022. vol. 198. pp. 59–66.

57. Ceker H., Upadhyaya S. User authentication with keystroke dynamics in long-text data. IEEE 8th International Conference on Biometrics Theory, Applications and Systems (BTAS). IEEE, 2016. pp. 1–6.
58. Wang X., Shi Y., Zheng K., Zhang Y., Hong W., Cao S. User Authentication Method Based on Keystroke Dynamics and Mouse Dynamics with Scene-Irrelated Features in Hybrid Scenes. *Sensors*. 2022. vol. 22. no. 17. pp. 6627.
59. Vural E., Huang J., Hou D., Schuckers S. Shared research dataset to support development of keystroke authentication. IEEE International joint conference on biometrics. IEEE, 2014. pp. 1–8.
60. Li J., Chang H.C., Stamp M. Free-text keystroke dynamics for user authentication. *Artificial Intelligence for Cybersecurity*. Cham: Springer International Publishing, 2022. pp. 357–380.
61. Sun Y., Ceker H., Upadhyaya S. Shared keystroke dataset for continuous authentication. IEEE International Workshop on Information Forensics and Security (WIFS). IEEE, 2016. pp. 1–6.
62. Ahmed A.A., Traore I. Biometric recognition based on free-text keystroke dynamics. *IEEE transactions on cybernetics*. 2013. vol. 44. no. 4. pp. 458–472.
63. Martin A.G., de Diego I.M., Fernandez-Isabel A., Beltran M., Fernandez R.R. Combining user behavioural information at the feature level to enhance continuous authentication systems. *Knowledge-Based Systems*. 2022. vol. 244. no. 108544. DOI: 10.1016/j.knosys.2022.108544.
64. Harilal A., Toffalini F., Castellanos J., Guarnizo J., Homoliak I., Ochoa M. Twos: A dataset of malicious insider threat behavior based on a gamified competition. *Proceedings of the International Workshop on Managing Insider Security Threats*. 2017. pp. 45–56.
65. Belman A.K. et al. Insights from BB-MAS--A Large Dataset for Typing, Gait and Swipes of the Same Person on Desktop, Tablet and Phone. *arXiv preprint arXiv:1912.02736*. 2019. 2019.
66. Killourhy K.S., Maxion R.A. Free vs. transcribed text for keystroke-dynamics evaluations. *Proceedings of the Workshop on Learning from Authoritative Security Experiment Results*. 2012. pp. 1–8.
67. Roth J., Liu X., Metaxas D. On continuous user authentication via typing behavior. *IEEE Transactions on Image Processing*. 2014. vol. 23. no. 10. pp. 4611–4624.
68. Iapa A.C., Cretu V.I. Shared Data Set for Free-Text Keystroke Dynamics Authentication Algorithms. 2021. DOI: 10.20944/preprints202105.0255.v1.
69. Bergadano F., Gunetti D., Picardi C. Identity verification through dynamic keystroke analysis. *Intelligent Data Analysis*. 2003. vol. 7. no. 5. pp. 469–496.
70. Banerjee R., Feng S., Kang J.S., Choi Y. Keystroke patterns as prosody in digital writings: A case study with deceptive reviews and essays. *Proceedings of the Conference on empirical methods in natural language processing (EMNLP)*. 2014. pp. 1469–1473.
71. Murphy C., Huang J., Hou D., Schuckers S. Shared dataset on natural human-computer interaction to support continuous authentication research. *IEEE International Joint Conference on Biometrics (IJCB)*. IEEE, 2017. pp. 525–530.
72. Kilic A.A., Yildirim M., Anarim E. Bogazici mouse dynamics dataset. *Data in Brief*. 2021. vol. 36. no. 107094.
73. Shen C., Cai Z., Guan X. Continuous authentication for mouse dynamics: A pattern-growth approach. *IEEE/IFIP International Conference on Dependable Systems and Networks (DSN 2012)*. IEEE, 2012. pp. 1–12.
74. Shen C., Cai Z., Guan X., Maxion R. Performance evaluation of anomaly-detection algorithms for mouse dynamics. *Computers and security*. 2014. vol. 45. pp. 156–171.

75. Antal M., Egyed-Zsigmond E. Intrusion detection using mouse dynamics. *IET Biometrics*. 2019. vol. 8. no. 5. pp. 285–294.
76. Fulop A., Kovacs L., Kurics T., Windhager-Pokol E. Balabit Mouse Dynamics Challenge data set. 2017. Available at: <https://github.com/balabit/Mouse-Dynamics-Challenge> (accessed: 16.10.2023).
77. Almalki S., Chatterjee P., Roy K. Continuous authentication using mouse clickstream data analysis. *Security, Privacy, and Anonymity in Computation, Communication, and Storage: SpaCCS Proceedings 12*. Springer International Publishing, 2019. pp. 76–85.
78. Antal M., Denes-Fazakas L. User verification based on mouse dynamics: a comparison of public data sets. *IEEE 13th International Symposium on Applied Computational Intelligence and Informatics (SACI)*. IEEE, 2019. pp. 143–148.
79. Weiss G.M. Wism smartphone and smartwatch activity and biometrics dataset. *UCI Machine Learning Repository: WISDM Smartphone and Smartwatch Activity and Biometrics Dataset Data Set*. 2019. vol. 7. pp. 133190–133202.
80. Matveev Ju.N. [Study of the informativeness of speech features for automatic speaker identification systems]. *Izvestija vysshih uchebnyh zavedenij. Priborostroenie – News of higher educational institutions. Instrumentation*. 2013. vol. 56. no. 2. pp. 47–51. (In Russ.).
81. Starodubov D.N. [Methods for determining the informativeness of features of objects]. *Algoritmy, metody i sistemy obrabotki dannyh – Algorithms, methods and data processing systems*. 2008. no. 13. pp. 140–146. (In Russ.).
82. Frank E., Hall M., Holmes G., Kirkby R., Pfahringer B., Witten I.H., Trigg L. *Weka-a machine learning workbench for data mining. Data mining and knowledge discovery handbook*. 2010. pp. 1269–1277.
83. Sharma P., Singh D., Singh A. Classification algorithms on a large continuous random dataset using rapid miner tool. *2nd International Conference on Electronics and Communication Systems (ICECS)*. IEEE, 2015. pp. 704–709.
84. Zhigulin P.V., Mal'cev A.V., Mel'nikov M.A., Podvorchan D.E. [Network traffic analysis based on neural networks]. *Jelektronnye sredstva i sistemy upravlenija. Materialy dokladov Mezhdunarodnoj nauchno-prakticheskoj konferencii – Electronic means and control systems. Materials of reports of the International Scientific and Practical Conference*. 2013. no. 2. pp. 44–48. (In Russ.).
85. Bykova V.V., Kataeva A.V. [Methods and tools for analyzing the informativeness of features in the processing of medical data]. *Programmnye produkty i sistemy – Software products and systems*. 2016. no. 2(114). pp. 172–178.
86. Burton A, Parikh T., Mascarenhas S., Zhang J., Voris J., Artan N.S., Li W. Driver identification and authentication with active behavior modeling. *12th International Conference on Network and Service Management (CNSM)*. IEEE, 2016. pp. 388–393.
87. Milton L.C., Memon A. Intruder detector: A continuous authentication tool to model user behavior. *IEEE Conference on Intelligence and Security Informatics (ISI)*. IEEE, 2016. pp. 286–291.
88. Siddiqui N., Dave R., Vanamala M., Seliya N. Machine and deep learning applications to mouse dynamics for continuous user authentication. *Machine Learning and Knowledge Extraction*. 2022. vol. 4. no. 2. pp. 502–518.
89. Feher C., Elovici Y., Moskovitch R., Rokach L., Schelar A. User identity verification via mouse dynamics. *Information Sciences*. 2012. vol. 201. pp. 19–36.
90. Kuzminykh I., Mathur S., Ghita B. Performance Analysis of Free Text Keystroke Authentication using XGBoost. *Proc. of 6th International Conference on Computer Science, Engineering and Education Applications. (ICCSEA)*. 2023. pp. 429–439.

91. Agraftoti F., Bui F.M., Hatzinakos D. Secure telemedicine: Biometrics for remote and continuous patient verification. *Journal of Computer Networks and Communications*. 2012. vol. 2012. DOI: 10.1155/2012/924791.

Davydenko Sergey — Junior researcher, NTI competence center "trusted interaction technologies", Tomsk State University of Control Systems and Radioelectronics. Research interests: artificial intelligence and machine learning. The number of publications — 122. sergun_dav@mail.ru; 40, Lenina Av., 634050, Tomsk, Russia; office phone: +7(3822)51-3262.

Kostyuhenko Evgeny — Ph.D., Associate Professor, Head of the laboratory, Laboratory for reception, analysis and control of biological signals; Associate professor of the department, Department of integrated information security of electronic computing systems, Tomsk State University of Control Systems and Radioelectronics. Research interests: artificial intelligence and machine learning, speech processing, biometry, data analysis. The number of publications — 145. key@fb.tusur.ru; 40, Lenina Av., 634050, Tomsk, Russia; office phone: +7(3822)70-1529.

Novikov Sergey — Ph.D., Dr.Sci., Associate Professor, Head of the department, Department of security and management in telecommunications, Siberian State University of Telecommunications and Informatics. Research interests: artificial intelligence and machine learning. The number of publications — 122. snovikov@ngs.ru; 86, Kirova St., 630102, Novosibirsk, Russia; office phone: +7(3832)69-2245.

Acknowledgements. This research was funded by the Ministry of Science and Higher Education of Russia, Government Order for 2023–2025, project no. FEWM-2023-0015 (TUSUR).

N.V. HUNG, T.Q. LOI, N.H. BINH, N.T.T. NGA, T.T. HUONG, D.L. LUU **BUILDING AN ONLINE LEARNING MODEL THROUGH A DANCE RECOGNITION VIDEO BASED ON DEEP LEARNING**

Hung N.V., Loi T.Q., Binh N.H., Nga N.T.T., Huong T.T., Luu D.L. **Building an Online Learning Model Through a Dance Recognition Video Based on Deep Learning.**

Abstract. Jumping motion recognition via video is a significant contribution because it considerably impacts intelligent applications and will be widely adopted in life. This method can be used to train future dancers using innovative technology. Challenging poses will be repeated and improved over time, reducing the strain on the instructor when performing multiple times. Dancers can also be recreated by removing features from their images. To recognize the dancers' moves, check and correct their poses, and another important aspect is that our model can extract cognitive features for efficient evaluation and classification, and deep learning is currently one of the best ways to do this for short-form video features capabilities. In addition, evaluating the quality of the performance video, the accuracy of each dance step is a complex problem when the eyes of the judges cannot focus 100% on the dance on the stage. Moreover, dance on videos is of great interest to scientists today, as technology is increasingly developing and becoming useful to replace human beings. Based on actual conditions and needs in Vietnam. In this paper, we propose a method to replace manual evaluation, and our approach is used to evaluate dance through short videos. In addition, we conduct dance analysis through short-form videos, thereby applying techniques such as deep learning to assess and collect data from which to draw accurate conclusions. Experiments show that our assessment is relatively accurate when the accuracy and F1-score values are calculated. More than 92.38% accuracy and 91.18% F1-score, respectively. This demonstrates that our method performs well and accurately in dance evaluation analysis.

Keywords: online learning, deep learning, LSTM, GRU, RNN, Vietnam.

1. Introduction. Video technology research has been one of the hottest topics in recent years. Dance motion recognition, one of many video technologies, is critical for intelligent applications and is widely used in many aspects of life and education. Training and coaching a smart dance assistant takes significant time for the individual learner and the instructor. Some poses are difficult to perform repeatedly, impacting the psychology of students and teachers. The dancers' postures can be mapped using features extracted from their images. As a result, existing extraction techniques rely on this method to focus more on the video's spatial domain, that is, extract pixel information from video frames while ignoring changes in the motion state of the video motion in the time domain [1]. The process of transitioning from one movement to the next is critical because there are unrelated movements, making it difficult for learners to grasp the lessons.

Furthermore, all dance movements are based on human body movements [2]. The development of dance motion detection and recognition has been slow due to the complexity and breadth of dance movements. As

a result, technology assistance is required. In [3], dance motion recognition technology primarily needs to process activities that change in space and time to maintain stability when performing some dance movements, which is the primary goal of standard muscle training for general strength, strength, and bodybuilding.

Indeed, we can easily see two motion recognition methods: those based on manual features and those based on deep learning models. Although there are various aspects, deep learning is the primary technology to extract video features [4, 5]. Deep learning algorithms are used to recognize complex movements and capture them [6]. Through advanced features of many layers, deep learning has much higher generalizability than other methods [7]. Furthermore, classification [8, 9] and semantic segmentation [10, 11] outperform traditional methods. At the moment, depth neural networks are more commonly used by dividing them into many convolutional neural networks [12] that process both image data and string data. The cyclic neural network outperformed traditional classification methods and has gained widespread attention.

Many studies have shown that deep learning occurs primarily through learning and training a large amount of data [7, 13], with the goal of the parameters in the model exactly matching the rules given by the user to significantly reduce the gap between the original data, the target category, and perform the corresponding dance action recognition classification, through the use of the object's motion recognition technology. We can assess a dancer's jump position and suggest modifications by comparing the move with a standard action. Our dance motion recognition system will be significantly improved, especially today, as learning and teaching have become commonplace in the internet age as universities want to expand internships online with modern technology. Technology can evaluate teachers or judges in dance competitions or sports for performing complex moves. Figure 1 is an experimental case depicting how new research technology will replace humans. Instead of doing it manually, dance moves on stage will be marked automatically through technology. School needs are needed when teachers can only perform a few times per facility, and teachers can use this proposed method to improve assessment work.

Dance has become as famous worldwide as in India [14]. However, in Vietnam, when it comes to physical education and sports, generally referred to as physical education, most people immediately think of athletics, football, volleyball, badminton, etc. A few think about dancing because this subject has received little attention in Vietnamese universities based on the necessary conditions in Vietnam.

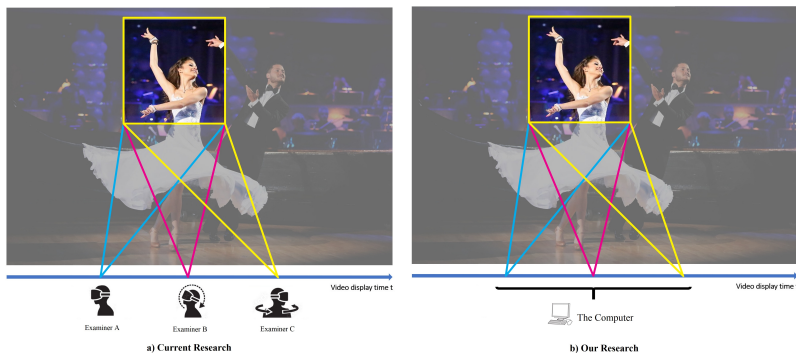


Fig. 1. a) **Current Research**: The examiner looks at the live dance, evaluates it, and gives it a live score; b) **Our Research**: We build and store the model on the computer; the computer will calculate and give the score directly

In Vietnam, processed videos are often analyzed and processed in manual evaluation, and some deep learning techniques have been widely used recently. However, contributions are still limited. Therefore, applying deep learning and video analysis techniques to classify dances from a computer perspective is necessary. Furthermore, because students at university in Vietnam need a realistic view of their experience, recorded videos help them describe the practice. On the one hand, there needs to be more experimentation in Vietnam with online video in teacher training and other professional training programs using web video applications. In our system, to support self-assessment, students must be familiar with the assessment standards and the criteria they represent. When trained, our system thus improves the quality and aids in evaluating each regular and memorable dance. Our system will help consider a teacher's comments critically and act more. On the other hand, subjective evaluations significantly impact the outcomes of dance participants. Therefore, safety and trust should be established during the assessment process, mainly when dealing with sensitive issues related to complex life. Consequently, we formulate the scientific novelty of the paper as follows: the proposed method can replace the current manual model; the proposed process will automatically evaluate and give direct results, avoiding waiting time from manual evaluation. The model is used for active online learning through trained videos. The experimental results are practical models of 3 models, RNN, LSTM, and GRU, with evaluation rates of 91.88%, 95.96%, and 96.98%, respectively.

This paper is organized as follows: Section 2 discusses the related work. Section 3 presents the concepts and features of identifying fake news on social

networks. Section 4 describes the suggested viewport estimation technique. Section 5 contains the performance assessment. Section 6 concludes with a discussion of our conclusions and open questions.

2. Related work. In [15], the algorithm provides a robust and trusted environment for video transactions by incorporating the FISCO alliance chain for secure transaction management and leveraging trusted computing techniques for video processing. It combines the benefits of blockchain technology, secure communication, and hardware-based security to enhance the video transaction process's overall security, integrity, and transparency without focusing on processing and dance analysis techniques in the dancer video.

On the other hand, the methods recently, the author will use deep learning, the procedures generally looking for ways to differentiate and predict and provide better prospects, such as [16, 17]; the author focuses on analyzing user behavior and then focuses on a series of behavioral recognition algorithms based on image and bone data; deeply examine their theories and performance, and finally offer further perspectives. However, this application still has many limitations, such as the fact that each person's behavior changes over time, and in the coming years, as people and society change, attitudes toward behavior assessment will also change. In [17], the author focuses on its construction as a dance figure classification problem using three-dimensional body joints and wearable sensors based on long short-term memory (LSTM), and it includes time- and orbit-wise structure using orbital information in timestamps and time-mask modules. However, as stated by the author, the author relies on three-dimensional body joints and sensors, which has the limitation that the research will heavily depend on the sensor. According to a recent study [18], the author recommends short-form videos on TikTok and songs and dances for users to repeat. However, the author only investigates the social spread of TikTok challenges by predicting user engagement and combining potential users and challenge representatives from previous videos to perform this user challenge prediction task. As a result, the author still needs to address the training issue and has limited his analysis to the dances in the video.

Furthermore, the advancement of Internet technology has brought opportunities and challenges for dance education in colleges and universities. Traditional dance instruction in universities still needs to meet students' needs [19]. Effective reform measures must be implemented to strengthen the reform of dance instruction in colleges and universities. The author proposes using dance teaching in universities as a research breakthrough while also researching and analyzing the methods of teaching dance in the new era in depth. Besides, researchers and technical staff have taken notice of a recent new

study that used virtual reality technology in multimedia technology to create a teaching system that simulates dance sports in [20, 21]. However, the author is primarily divided into two aspects to explore the inevitable dance process of editing the actions of virtual humanoid technology dancers. Finally, regarding the three movements included in the final sport dance teaching, the author focuses on fundamentally solving the shortcomings of contemporary dance sports teaching while offering sports-specific solutions and measures. In [21], the author also explains the related concepts of virtual reality technology dance teaching in colleges and universities. In general, the studies only focused on teaching work but did not focus on video analysis for processing, thereby making a final assessment of video analysis and processing.

Dance movement is becoming an increasingly common research topic in the broader field of human motion analysis [6]. Recent approaches primarily employ recurrent neural networks (RNNs), which have been shown to accumulate prediction errors, limiting models that synthesize short choreography to less than 100 poses. The author [22] also proposes a multimodal convolutional autoencoder capable of generating novel dance motion sequences of arbitrary length by combining 2D bone and audio information using an attention-based feature fusion mechanism. However, the author must consider the skeleton's characteristics as input in this method according to the previous model. This is only true for passive data sets, so our approach will carry out automatically when the data is transferred to the model for monitoring.

3. Theory background. In this section, we discuss some concepts, thereby discussing and recommending models for analysis and performance evaluation for future use models.

3.1. Dance identification. Counseling identification is an important area that many scientists focus on researching to serve life. Martial arts is considered the most exciting field in recent times. In [19 – 21, 23, 24], Sports dance is a sport that combines music with flexible, graceful, beautiful, and appealing movements. Currently, this sport is gradually becoming popular. It is practiced regularly, helping people exercise, improving exchanges and solidarity, and improving spiritual life quality. On the other hand, sports dance does not require high artistic and technical skills in daily practice, so in recent years, this subject has gradually become popular and developed rapidly and widely, with people of all ages, genders, and professions practicing together.

This subject not only brings health but also mental comfort to those who participate in the practice, assisting them in becoming more confident in themselves, meeting new friends, having a great time immersed in melodic music, and dispelling life's stress and depression. With the same starting point

as everyone's passion for sports, today's dance clubs are contributing to the development of the sport and physical training movement worldwide to improve everyone's health and spiritual life.

3.2. Discussion. In general, with the development of information technology, scientists have expanded and researched a lot in the evaluation, analysis, and comment models. Based on practical conditions, this paper analyzes three basic and widely used models below: RNN – Recurrent Neural Network, GRU – Gated Recurrent Unit, and LSTM – Long Short-Term Memory.

3.2.1. RNN – Recurrent Neural Network. RNN is a special machine learning model designed to process sequential data such as time series or time-dependent data [25]. An important feature of an RNN is its ability to maintain a hidden state during input data processing and reuse this information when processing subsequent components of sequential data. This allows the RNN to understand and preserve the context and temporal relationships between elements in the sequential data.

In dance recognition problems [26], RNNs can classify dances based on previous temporal information. To do this, we create an RNN with an LSTM or GRU layer to understand and model the material characteristics of the dances.

Suppose we have a data set of dance patterns recorded in a time series. Each dance pattern can be represented as feature vectors, and we need to feed them into the RNN to classify them as corresponding to different dances.

The RNN model is built with several layers, in which the first layer is an LSTM layer, then Dropout layers to avoid overfitting, and finally, a Dense layer with softmax activation function to perform classification. Once the model trains on the dataset, it recognizes new dances that have not been seen before by relying on the knowledge of dance patterns learned from the training set. While RNN has advantages in sequential data processing, it also faces some limitations, such as the problem of vanishing gradients and the difficulty of long-term information retention.

RNN is a powerful tool for dance recognition and other sequential data processing [27]. Combining LSTM layers helps the model understand and mimic complex time patterns and predict and classify dances accurately. First, an embedding layer is pushed in. Next, ignore the already stored space to remove the standalone feature that dropout keeps. The SimpleRNN class uses 50 units in Figure 2. Each type identifies with five topics. Next, the Dense class is used to classify feature features based on the outputs from the composite courses.

On the other hand, we perform classification using the softmax activation function commonly used for the output layer. Softmax ensures

that the predicted probabilities across all classes sum up to 1, providing a probability distribution over the classes. Besides, the appropriate loss function for multi-class classification with softmax activation is the categorical cross-entropy loss. This loss function measures the dissimilarity between the predicted probability distribution and the actual class labels.

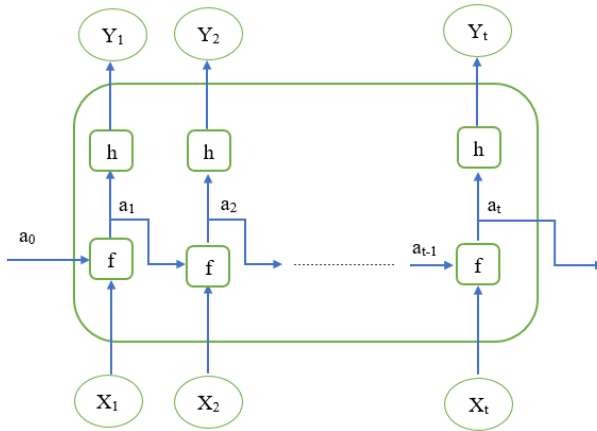


Fig. 2. Algorithm for RNN model

For the RNN model, for the input value x_t , there will be a corresponding y_t value. The process of using our RNN model is as follows:

$$a_t = f(T_a * x_t + W_a * a_{t-1}), \quad (1)$$

$$y_t = h(V_a * a_t), \quad (2)$$

where T_a , V_a , and W_a are learnable weight matrices; x is the input at t that is the one-hot vector corresponding to the size of $n - 1$; a_t is the hidden state at t that is calculated based on both the presiding state and input. y_t is the output at t , a probability vector of predicting words by learning information from all previous inputs.

3.2.2. GRU – Gated Recurrent Unit. GRU is a type of RNN developed to address limitations found in LSTM networks and enhance the performance of processing sequential data [28]. Like LSTM, the GRU maintains a hidden state to handle sequential information and learn intricate timing patterns. However, the GRU simplifies the LSTM architecture by eliminating sure gates and

replacing them with a single gate mechanism. This modification results in a more straightforward structure for the GRU to understand and work with.

The gate mechanism in the GRU allows the model to decide what information should be ignored and hidden. This helps the model focus on the important factors in the sequential data and reduces problems such as disappearing gradients during training.

In the dance recognition problem, GRU builds a dance classification model based on sequential data of dance features. Each dance pattern can be represented as feature vectors and fed into the GRU network to learn the designs and the time dependence between dances.

The GRU is built with a simple GRU layer, followed by Dropout layers, to avoid overfitting – finally, a Dense layer with a softmax activation function to perform multiclass classification. Thanks to the unique gate mechanism and the smaller number of parameters compared to LSTM, GRUs typically train faster and require fewer resources. GRU is popular for sequential data processing problems, including dance recognition.

GRU is an efficient variant of recurrent neural networks in recognizing and classifying dances based on sequential data [29]. This makes processing temporal data in dance applications easier and is highly efficient in identifying and classifying different dance patterns. In Figure 3 simulates our calculation algorithm; we recalculate the values using the formulas for the gates Reset gate (r_t), Update gate (z_t), Candidate hidden state (h'_t), and Hidden state (h_t) as follows:

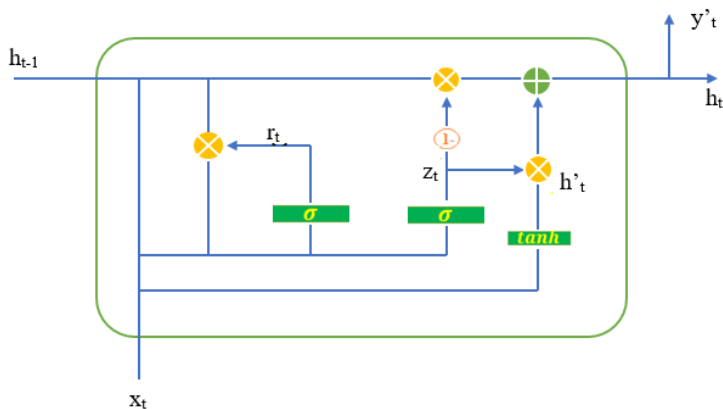


Fig. 3. Algorithm for GRU unit

$$r_t = \sigma(W_r * [h_{t-1}, x_t]), \quad (3)$$

$$z_t = \sigma(W_z * [h_{t-1}, x_t]), \quad (4)$$

$$h'_t = \tanh(W_h * [r_t * h_{t-1}, x_t]), \quad (5)$$

$$h_t = (1 - r_t) * h_{t-1} + z_t * h'_t, \quad (6)$$

where W_r , W_z , and W_h are learnable weight matrices, x_t is the input x_t time step t , h_{t-1} is the previous hidden state, and h_t is the current hidden state. Besides, y'_t is used for passing information to future time steps and computing the output.

3.2.3. LSTM – Long Short Term Memory. LSTM is an RNN architecture that processes sequential data with complex long-term and short-term characteristics [28, 30]. LSTM helps to solve the problem of gradient vanishing and the difficulty of long-term information retention in conventional RNNs. This makes LSTM a powerful tool for handling complex sequential data such as time series or natural language.

In the dance recognition problem, LSTM builds a dance classification model based on the temporal information of the dance features [14]. Each dance pattern is represented as feature vectors and fed into the LSTM network to learn the designs and the time dependence between dances. The LSTM model is built with an LSTM layer, then Dropout layers to avoid overfitting, and finally, a Dense layer with a softmax activation function to perform multiclass classification.

The ability to store long-term information in long-term memory is an important feature of LSTM. This allows the model to capture the dances' complex relationships and temporal structure. Long-term memory helps the model recognize intricate dance patterns based on information learned from the training set and then applies this knowledge to recognize new dances that have not been seen before. Although LSTM has outstanding advantages in handling complex sequential data, it also requires more computational resources than other models, such as GRU. This can sometimes make it difficult to train and deploy the model.

LSTM is a recurrent neural network architecture powerful in recognizing and classifying dances based on temporal information of dance features. This makes time data processing in dance applications efficient

and reliable and allows identifying complex and varied dance patterns. In Figure 4 simulates our calculation algorithm; we recalculate the values using the formulas for the gates Forget gate (z_t), Input gate (y_t), Output gate (n_t) as follows:

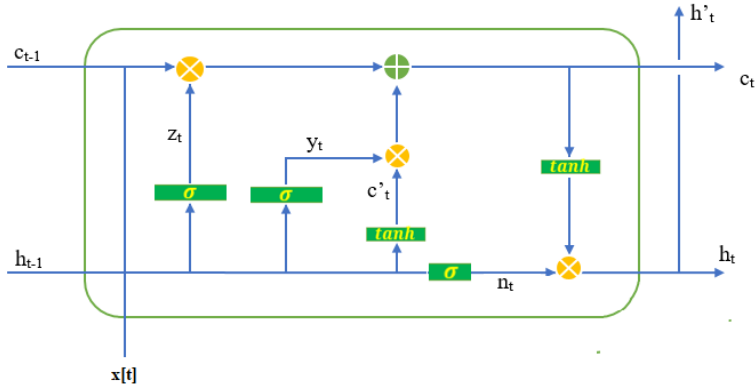


Fig. 4. Algorithm for LSTM cell

$$z_t = \sigma(U_z * x_t + W_z * h_{t-1} + b_z), \quad (7)$$

$$y_t = \sigma(U_y * x_t + W_y * h_{t-1} + b_y), \quad (8)$$

$$n_t = \sigma(U_n * x_t + W_n * h_{t-1} + b_n), \quad (9)$$

$$c'_t = \tanh(U_c * x_t + W_c * h_{t-1} + b_c), \quad (10)$$

$$c_t = z_t * c_{t-1} + y_t * c'_t, \quad (11)$$

$$h_t = h'_t = n_t * \tanh(c_t), \quad (12)$$

where $U_z, U_y, U_n, U_c, W_z, W_y, W_n,$ and W_n are learnable weight matrices, $b_z, b_y,$ and b_n are bias coefficients, x_t is the input x_t time step t , h_{t-1} is the previous hidden state, and h_t is the current hidden state. c_t is the forget gate that decides how much to get from the cell state first, and the input gate decides how much

to take from the input of the state and a hidden layer of the previous layer. Besides, h_t is the output gate that decides how much to take from the cell state to be the output of the hidden state. In addition, h_t is also used to calculate the output h'_t for state t .

3.2.4. Loss function. A loss function is a function that measures the difference between the model's predicted value and the ground truth. We calculate the loss function using the following formula:

$$Loss = -\frac{1}{N} \sum_{i=1}^N \log(\rho(y_i|x_i)), \quad (13)$$

where N is the number of training samples,

x_i is the input data of the i sample,

y_i : is the actual label of the i sample,

$\rho(y_i|x_i)$: is the probability that the model correctly predicts label y_i for data x_i .

4. Proposed model. In this section, we present the proposed method and the model we use. The article is analyzed and proposed with three separate models: RNN, GRU, and LSTM. Detailed descriptions are provided in the following sections.

4.1. Problem Formulation. Dancing is a type of sport that most students are interested in when they want to exercise their health and can solve boring problems in life, with the desire to change the lifestyle of society and change the daily life of Vietnamese people. Besides that, the aspect changes, and towards the competition expands beyond the country.

In addition, higher education in Vietnam aims to be more comprehensive. Therefore, this study also seeks to build a quality assessment team for university dance. Besides, analyze dances to cluster and evaluate dance classification for each object, thereby extracting information. In this section, we identified five popular dance types in Vietnam corresponding to 5 trends on social networks: "Heyhey," "Kynqucfan," "Thuyen Quyen," "Trong Hoa," and "Mua Bai Vietnam" dance. Each type of dance consists of a set of basic movements represented by corresponding landmarks on the body.

The way we do it is as follows. We used landmarks from the Mediapipe Pose to show the moves. Each landmark is represented by a vector by:

$$\Phi_i = (x_i, x_{i+1}, \dots, x_{i+n-1}), \quad (14)$$

where x_i ($1 < i < n$) are the x coordinates of the i landmark. Next, we use geometric analysis and linear algebra to determine the degree of correlation between landmarks by calculating the Euclidean distance between landmark points. Finally, Building a Dance Recognition Model After extracting landmarks and performing analysis, we make a machine learning model to recognize the dances. The model includes hidden layers to learn complex relationships between landmarks and correlations. To do this, we calculate according to the following formula:

Step 1: Calculate the expected vector of all data, with N data points represented by the column vectors x_1, x_2, \dots, x_n , then the expectation vector and the covariance matrix of the entire data are defined as:

$$\bar{x} = \frac{1}{N} \sum_{n=1}^N x_n. \quad (15)$$

Step 2: Subtract each data point from the expected vector of all data by:

$$\hat{x} = x_n - \bar{x}. \quad (16)$$

Step 3: Calculate the covariance matrix by:

$$S = \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})(x_n - \bar{x})^T = \frac{1}{N} \hat{x} \hat{x}^T. \quad (17)$$

Thus, to calculate the eigenvalues and eigenvectors with a norm equal to 1 of this matrix, we arrange them in descending order of eigenvalues, with K eigenvectors corresponding to K largest eigenvalues to build a matrix U_K with columns forming an orthogonal system. Furthermore, these K vectors, also called principal components, include a subspace close to the distribution of the normalized initial data. Projecting the original data normalized \hat{x} down the subspace finds new data, which is the coordinates of the data points on the new space as follows:

$$Z = U_K^T * \hat{x}. \quad (18)$$

Thus, the original data can be approximated according to the new data as follows:

$$x = U_K * Z + \bar{x}. \tag{19}$$

After determining the correlation of the data, we analyze and put in the models presented above for training.

4.2. Design and problem solve. In this section, we design a model to evaluate the dance in Figure 5. We created this model to expect the model to consider each dancer automatically for each video. We pulled some images from selected videos, as shown in Figure 6.

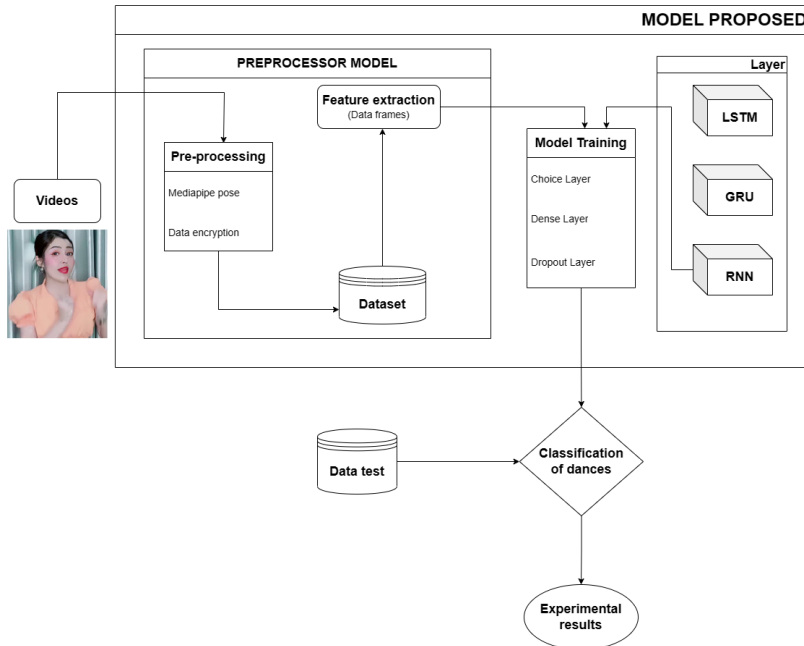


Fig. 5. Procedures for receiving and handling dancer information of our




a) Video #1



b) Video #2



c) Video #3



d) Video #4

Fig. 6. Some images represent some videos extracted from the experiment

After being trained and trained, the specific model is analyzed as follows:

– **Step 1:** The first data is the videos to be injected and preprocessed through the Mediapipe. Mediapipe is a very accurate and lightweight body gesture detection library. So, we used Mediapipe to assign body gestures to identify objects and categorize them later. We can see that Figure 7 shows the process of validating dance gestures using Mediapipe. Besides, we also encode the data to know the data into the data with the middle sentence and save the data set for training in the following steps.




Fig. 7. a) Original image extracted from the video; b) Point-assigned image

– **Step 2:** After the data is normalized, the data will be saved to the Dataset and the area partition as shown in Figure 8; the data will be used based on the features to extract into the models. Thus, steps one and two, which are our proposed system, these steps perform data preprocessing and feature extraction to get into training models. Their recommendation system implements this process to improve the direct processing of the data before it is fed to the training models, thus reducing the training load.

Furthermore, the Extracting Feature will be the analysis content of the video will be converted to a vector to create a folder to use the features in the video. Each dance is labeled, analyzed, and given the corresponding numbers. Each dance is converted to an array with fixed-assigned natural numbers.




Fig. 8. Data Partition of Model

– **Step 3:** As shared in steps 1 and 2, these are two essential steps that support the implementation and training of models. In this step, after the data is preprocessed and extracted features are sent to the model, the Modes will drop unnecessary features, traversing the classes to train and storing the parts for later testing.

Moreover, the poses in training will be relevant if there is a wrong posture, and our system will find and analyze the mistakes that the dancer often encounters. In this section, the system will clearly show some typical features that dance encounters in the training data set. After being stored and analyzed, data will be saved as feature vectors. During training, the model can extract this feature to give warnings and guide the dancer through challenging poses.

5. Performance Evaluation

5.1. Experimental Settings. In this paper, we use five dances, each with ten videos. These are short-format videos, less than 20 seconds in length. The experiment was conducted on a Windows 10 computer using an ASUS Rog Strix G15 G513IC Laptop with a Ryzen 7- 4800H processor, 16 GB RAM, and an RTX 3050 4GB graphics card. Moreover, to test our model, we conduct the video extraction evaluation analysis into two parts from the dynamic; part 1 consists of 80% for the training and the remaining 20% for testing. The

language we use is the python programming language with the libraries used including:

- Mediapipe: we use it to detect body gestures;
- Pandas: We use it to build data structures;
- Opencv-python-headless: We use it for video processing;
- Tensorflow: We use to compute, train, and infer deep neural networks;
- Scikit-learn: We use it to handle classification problems.

In addition, we set up each model to 50 units, Dropout (0.2), Dense(units = 1, activation = "sigmoid"), and each model saves on a file with the extension h5.

5.2. Performance evaluation. The precision, recall, accuracy, and F1-score criteria assessed the model performance. Table 1 [6, 9] shows the parameters, which are as follows:

- TP: The model predicts 1 while actually, it is 1;
- TN: The model predicts 0 while actually, it is 0;
- FN: The model predicts 0, but the truth is 1;
- FP: The model predicts 1, but the truth is 0.

Table 1. Matrix of confusion

Labels	Positive prediction	Negative prediction
<i>Positive action</i>	False positive (FP)	True negative (TN)
<i>Negative action</i>	True positive (TP)	False negative (FN)

On the other hand, the Precision is calculated as the number of positive points divided by the total points of TP and FP as follows:

$$Pre = \frac{TP}{TP + FP}. \quad (20)$$

Recall is calculated as the number of positive points divided by the total points of TP and FN as follows:

$$Rec = \frac{TP}{TP + FN}. \quad (21)$$

Accuracy is determined by the sum of TP and TN overall points on the sum of TP, TN, FP, and FN as follows:

$$Ac = \frac{TP + TN}{TP + TN + FP + FN}. \quad (22)$$

Finally, the F1-score is calculated as follows:

$$\frac{F1}{2} = \frac{Pre}{Pre + Rec} * \frac{Rec}{Pre + Rec}. \quad (23)$$


5.3. Results. Experiments show that all three methods show stable results. In five independent runs, the GRU model method gives the best results, and the RNN gives the most limited results in Table 2.

Table 2. Experimental results of 3 models RNN, GRU, LSTM


Value	Nu. of times for testing	LSTM	RNN	GRU
F1-score (%)	1	98.42	92.7	94.87
	2	95.31	86.93	96.65
	3	96.58	92.22	97.58
	4	95.19	91.03	98.24
	5	98.36	92.3	98.22
Average		96.77	91.04	97.11
Accuracy (%)	1	98.48	92.81	94.94
	2	95.41	87.43	96.84
	3	96.73	92.43	97.66
	4	95.48	91.08	98.29
	5	98.46	92.58	98.27
Average		96.91	91.27	97.20
Loss (%)	1	4.57	21.93	15.63
	2	13.69	36.19	8.83
	3	9.4	23.27	7.05
	4	14.23	25.78	4.97
	5	4.87	20.83	5.12
Average		9.35	25.60	8.32

Experimentally, we can see that using the model of GRU is the best choice when the F1-score value reaches about 97.11%, followed by LSTM and RNN, respectively. Besides, the Loss or Accuracy values also show promising results when Accuracy offers is 97.20%, while the loss value is 8.32%. For the RNN model, the loss value of 25.60% is relatively high and three times higher than that of the LSTM model at 9.35%.


Overall, Model GRU showed better results with three models than the LSTM and RNN models. However, the experimental results are processed in short video formats. Our future direction will be to conduct more reviews with longer videos. Table 2, Figures 9, 10, and 11 show the results for each time to experiment.



a) Random experimental model RNN - time 1




b) Random experimental model RNN - time 2




c) Random experimental model RNN - time 3

d) Random experimental model RNN - time 4




e) Random experimental model RNN - time 5

Fig. 9. Accuracy and Loss value of RNN model



a) Random experimental model GRU - time 1




b) Random experimental model GRU - time 2




c) Random experimental model GRU - time 3

d) Random experimental model GRU - time 4




e) Random experimental model GRU - time 5


Fig. 10. Accuracy and Loss value of GRU model



a) Random experimental model LSTM - time 1




b) Random experimental model LSTM - time 2



c) Random experimental model LSTM - time 3

d) Random experimental model LSTM - time 4



e) Random experimental model LSTM - time 5

Fig. 11. Accuracy and Loss value of LSTM model

6. Conclusions. The dance classification plays the most important role in online learning through video tutorials. This paper proposes a model to classify and evaluate dance based on RNN, GRU, and LSTM models. The GRU algorithm showed better results for this study in short-form videos. However, our experiments show that our proposed models achieve a reasonable f1-score rate of over 91%. In which GRU is approximately 97%. The article's contribution is processing videos and thereby improving online learning tools for students at universities in Vietnam.

In addition, our method can evaluate learners without requiring a study coach or a panel of judges to comment. We can learn continuously and repeat many times for complex dance.

However, our method also has a few limitations, as follows:

- First: the experimental model for short-form video.
- Second: the current model has limited data, so it only works with trained videos; in case the model has not been trained, it needs to be trained, so it takes time to train.

Therefore, in the future, we plan to build a reinforcement learning model to limit the need to retrain the mode and expand the study of longer videos.

References

1. Zhai X. Dance movement recognition based on feature expression and attribute mining. *Complexity*. 2021. vol. 2021. pp. 1–12.
2. Krishna V.B. Ballroom dance movement recognition using a smart watch. arXiv preprint. 2020. arXiv:2008.10122.
3. Sun Y., Chen J. Human movement recognition in dancesport video images based on chaotic system equations. *Advances in Mathematical Physics*. 2021. vol. 2021. pp. 1–12.
4. Zhang J., Sun J., Wang J., Yue X.-G. Visual object tracking based on residual network and cascaded correlation filters. *Journal of ambient intelligence and humanized computing*. 2021. vol. 12. pp. 8427–8440.
5. Zhou Q., Wang J., Wu P., Qi Y. Application development of dance pose recognition based on embedded artificial intelligence equipment. *Journal of Physics: Conference Series*. 2021. vol. 1757(1). no. 012011.
6. Nguyen H., Dao T.N., Pham N.S., Dang T.L., Nguyen T.D., Truong T.H. An accurate viewport estimation method for 360 video streaming using deep learning. *EAI Endorsed Transactions on Industrial Networks and Intelligent Systems*. 2022. vol. 9. no. 4. DOI: 10.4108/eetinis.v9i4.2218.
7. Wang S., Li J., Cao T., Wang H., Tu P., Li Y. Dance emotion recognition based on laban motion analysis using convolutional neural network and long short-term memory. *IEEE Access*. 2020. vol. 8. pp. 124928–124938.
8. Ding Y., Zhang Z., Zhao X., Cai Y., Li S., Deng B., Cai W. Self-supervised locality preserving low-pass graph convolutional embedding for large-scale hyperspectral image clustering. *IEEE Transactions on Geoscience and Remote Sensing*. 2022. vol. 60. pp. 1–16.
9. Hung N., Loi T., Huong N., Hang T.T., Huong T. Aafndl – an accurate fake information recognition model using deep learning for the vietnamese language. *Informatics and Automation*. 2023. vol. 22. no. 4. pp. 795–825.

10. Hao S., Zhou Y., Guo Y. A brief survey on semantic segmentation with deep learning. *Neurocomputing*. 2020. vol. 406. pp. 302–321.
11. Cai W., Song Y., Duan H., Xia Z., Wei Z. Multi-feature fusion-guided multiscale bidirectional attention networks for logistics pallet segmentation. *Computer Modeling in Engineering and Sciences*. 2022. vol. 131. no. 3. pp. 1539–1555.
12. Zhao M., Chang C.H., Xie W., Xie Z., Hu J. Cloud shape classification system based on multi-channel cnn and improved fdm. *IEEE Access*. 2020. vol. 8. pp. 44111–44124.
13. Bakalos N., Rallis I., Doulamis N., Doulamis A., Protopapadakis E., Voulodimos A. Choreographic pose identification using convolutional neural networks. 11th International Conference on Virtual Worlds and Games for Serious Applications (VS-Games). IEEE, 2019. pp. 1–7.
14. Rani C.J., Devarakonda N. An effectual classical dance pose estimation and classification system employing convolution neural network–long shortterm memory (CNN-LSTM) network for video sequences. *Microprocessors and Microsystems*. 2022. vol. 95. no. 104651.
15. Yang Y., Yu D., Yang C. Video transaction algorithm considering fisco alliance chain and improved trusted computing. *PeerJ Computer Science*. 2021. vol. 7. no. e594.
16. Hu K., Jin J., Zheng F., Weng L., Ding Y. Overview of behavior recognition based on deep learning. *Artificial Intelligence Review*. 2023. vol. 56. no. 3. pp. 1833–1865.
17. Matsuyama H., Aoki S., Yonezawa T., Hiroi K., Kaji K., Kawaguchi N. Deep learning for ballroom dance recognition: A temporal and trajectory-aware classification model with three-dimensional pose estimation and wearable sensing. *IEEE Sensors Journal*. 2021. vol. 21. no. 22. pp. 25437–25448.
18. Ng L.H.X., Tan J.Y.H., Tan D.J.H., Lee R.K.-W. Will you dance to the challenge? predicting user participation of TikTok challenges. *Proceedings of the IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*. 2021. pp. 356–360.
19. He H., Luo Q. Online teaching mode of college sports dance course under the background of internet plus. *International Conference on Information Technology and Contemporary Sports (TCS)*. 2021. pp. 160–164.
20. Zhu X. Research on the application of digital media technology in sports dance teaching. *International Conference on Education, Information Management and Service Science (EIMSS)*. 2021. pp. 22–26.
21. Hu Z. Research on the application of virtual reality technology in the teaching of sports dance in colleges and universities. *2nd International Conference on Artificial Intelligence and Education (ICAIE)*. 2021. pp. 414–418.
22. Kritsis K., Gkiokas A., Pikrakis A., Katsouros V. Danceconv: Dance motion generation with convolutional networks. *IEEE Access*. 2022. vol. 10. pp. 44982–45000.
23. Chen Y., Li X. Research on the application of flipped classroom model in college sports dance teaching. *International Conference on Information Technology and Contemporary Sports (TCS)*. 2021. pp. 508–511.
24. Li Y., Xu K. Online sports dance body contour extraction and training algorithm based on dsp chip intelligent high-definition camera image processing. *7th International Conference on Communication and Electronics Systems (ICCES)*. 2022. pp. 908–911.
25. Kaur M., Mohta A. A review of deep learning with recurrent neural network. *International Conference on Smart Systems and Inventive Technology (ICSSIT)*. 2019. pp. 460–465.
26. Rallis I., Voulodimos A., Bakalos N., Protopapadakis E., Doulamis N., Doulamis A. Machine learning for intangible cultural heritage: a review of techniques on dance analysis. *Visual Computing for Cultural Heritage*. 2020. pp. 103–119.

27. Biswal A. Recurrent neural network (RNN) tutorial: Types, examples, LSTM and more. Simplilearn. Com. Retrieved. 2022. Available at: <https://www.simplilearn.com/tutorials/deep-learning-tutorial/rnn> (accessed: 05.10.2023).
28. Zargar S. Introduction to sequence learning models: RNN, LSTM, GRU. Department of Mechanical and Aerospace Engineering, North Carolina State University. 2021. DOI: 10.13140/RG.2.2.36370.99522.
29. Zhang W., Li H., Tang L., Gu X., Wang L., Wang L. Displacement prediction of jiuxianping landslide using gated recurrent unit (gru) networks. Acta Geotechnica. 2022. vol. 17. no. 4. pp. 1367–1382.
30. Li W., Wei Y., An D., Jiao Y., Wei Q. LSTM-TCN: Dissolved oxygen prediction in aquaculture, based on combined model of long short-term memory network and temporal convolutional network. Environmental Science and Pollution Research. 2022. vol. 29. no. 26. pp. 39545–39556.

Nguyen Viet Hung — Ph.D., Lecturer, East Asia University of Technology; Student, Faculty of telecommunications engineering, Hanoi University of Science and Technology. Research interests: multimedia communications, network security, artificial intelligence, traffic engineering in next-generation networks, QoE/QoS guarantee for network services, green networking, applications. The number of publications — 16. hungnv@eaut.edu.vn; Ky Phu - Ky Anh, Ha Tinh, Viet Nam; office phone: +84(098)911-2079.

Thang Quang Loi — Research assistant, East Asia University of Technology. Research interests: applications, networks. The number of publications — 2. thangquangloi21@gmail.com; Xuan Long, Yen Binh, Yen Bai, Viet Nam; office phone: +84(084)6203-0902.

Nguyen Hai Binh — Lecturer, Faculty of information technology, East Asia University of Technology. Research interests: multimedia communications, database management systems, artificial intelligence, applications. The number of publications — 1. binhnh@eaut.edu.vn; Chien Thang - Thi Tran Xuan Mai, Chuong My, Hanoi, Viet Nam; office phone: +84(090)627-8669.

Nguyen Thi Thuy Nga — Lecturer, Faculty of information technology, East Asia University of Technology. Research interests: multimedia communications, database management systems, artificial intelligence, applications. The number of publications — 1. ngantt@eaut.edu.vn; Ta Thanh Oai - Thanh Tri, Hanoi, Viet Nam; office phone: +84(097)529-4770.

Truong Thu Huong — Ph.D., Dr.Sci., Deputy head of the department, School of electrical and electronic engineering, Hanoi University of Science and Technology. Research interests: network security, artificial intelligence, traffic engineering in next-generation networks, QoE/QoS guarantee for network services, green networking, and development of the Internet of Things ecosystems, applications. The number of publications — 90. huong.truongthu@hust.edu.vn; 1, Dai Co Viet St., Hanoi, Viet Nam; office phone: +84(243)869-2242.

Duc Lich Luu — Lecturer, University of Science and Technology. Research interests: vehicle dynamics control, cooperative driving, model-based predictive control, networked control systems. The number of publications — 30. ldlich@dut.udn.vn; 54, Nguyen Luong Bang St., 550000, Da Nang, Viet Nam; office phone: +84(0236)384-2308.

Н.В. Хунг, Т.К. Лои, Н.Х. Бинь, Н.Т. Нга, Т.Т. Хьонг, Д.Л. Луу ПОСТРОЕНИЕ МОДЕЛИ ОНЛАЙН-ОБУЧЕНИЯ С ПОМОЩЬЮ ВИДЕО ПО РАСПОЗНАВАНИЮ ТАНЦЕВ, ОСНОВАННОГО НА ГЛУБОКОМ ОБУЧЕНИИ

Хунг Н.В., Лои Т.К., Бинь Н.Х., Нга Н.Т., Хьонг Т.Т., Луу Д.Л. Построение модели онлайн-обучения с помощью видео по распознаванию танцев, основанного на глубоком обучении.

Аннотация. Распознавание движений при прыжках с помощью видео является значительным вкладом, поскольку оно значительно влияет на интеллектуальные приложения и будет широко применяться в жизни. Этот метод может быть использован для обучения будущих танцоров с использованием инновационных технологий. Сложные позы будут повторяться и совершенствоваться с течением времени, что снизит нагрузку на инструктора при многократном выполнении. Танцоров также можно воссоздать, удалив элементы из их изображений. Распознавать движения танцоров, проверять и корректировать их позы, и еще одним важным аспектом является то, что наша модель может извлекать когнитивные функции для эффективной оценки и классификации, а глубокое обучение в настоящее время является одним из лучших способов сделать это для возможностей коротких видеороликов. Кроме того, при оценке качества видеозаписи выступления точность выполнения каждого танцевального шага является сложной проблемой, когда глаза судей не могут на 100% сфокусироваться на танце на сцене. Более того, танцы на видео сегодня представляют большой интерес для ученых, поскольку технологии все больше развиваются и становятся полезными для замены людей. Основываясь на реальных условиях и потребностях Вьетнама. В этой статье мы предлагаем метод, заменяющий ручную оценку, и наш подход используется для оценки танца с помощью коротких видеороликов. Кроме того, мы проводим танцевальный анализ с помощью коротких видеороликов, применяя таким образом такие методы, как глубокое обучение, для оценки и сбора данных, на основе которых можно делать точные выводы. Эксперименты показывают, что наша оценка является относительно точной, когда рассчитываются значения точности и F1-балла. Точность составляет более 92,38% и 91,18% F1-балла соответственно. Это демонстрирует, что наш метод хорошо и точно работает при анализе оценки танца.

Ключевые слова: планирование траектории, кинематическое планирование, примитивы движения, эвристический поиск.

Литература

1. Zhai X. Dance movement recognition based on feature expression and attribute mining. Complexity. 2021. vol. 2021. pp. 1–12.
2. Krishna V.B. Ballroom dance movement recognition using a smart watch. arXiv preprint. 2020. arXiv:2008.10122.
3. Sun Y., Chen J. Human movement recognition in dancesport video images based on chaotic system equations. Advances in Mathematical Physics. 2021. vol. 2021. pp. 1–12.
4. Zhang J., Sun J., Wang J., Yue X.-G. Visual object tracking based on residual network and cascaded correlation filters. Journal of ambient intelligence and humanized computing. 2021. vol. 12. pp. 8427–8440.

5. Zhou Q., Wang J., Wu P., Qi Y. Application development of dance pose recognition based on embedded artificial intelligence equipment. *Journal of Physics: Conference Series*. 2021. vol. 1757(1). no. 012011.
6. Nguyen H., Dao T.N., Pham N.S., Dang T.L., Nguyen T.D., Truong T.H. An accurate viewpoint estimation method for 360 video streaming using deep learning. *EAI Endorsed Transactions on Industrial Networks and Intelligent Systems*. 2022. vol. 9. no. 4. DOI: 10.4108/eetinis.v9i4.2218.
7. Wang S., Li J., Cao T., Wang H., Tu P., Li Y. Dance emotion recognition based on laban motion analysis using convolutional neural network and long short-term memory. *IEEE Access*. 2020. vol. 8. pp. 124928–124938.
8. Ding Y., Zhang Z., Zhao X., Cai Y., Li S., Deng B., Cai W. Self-supervised locality preserving low-pass graph convolutional embedding for large-scale hyperspectral image clustering. *IEEE Transactions on Geoscience and Remote Sensing*. 2022. vol. 60. pp. 1–16.
9. Hung N., Loi T., Huong N., Hang T.T., Huong T. Aafndl – an accurate fake information recognition model using deep learning for the vietnamese language. *Informatics and Automation*. 2023. vol. 22. no. 4. pp. 795–825.
10. Hao S., Zhou Y., Guo Y. A brief survey on semantic segmentation with deep learning. *Neurocomputing*. 2020. vol. 406. pp. 302–321.
11. Cai W., Song Y., Duan H., Xia Z., Wei Z. Multi-feature fusion-guided multiscale bidirectional attention networks for logistics pallet segmentation. *Computer Modeling in Engineering and Sciences*. 2022. vol. 131. no. 3. pp. 1539–1555.
12. Zhao M., Chang C.H., Xie W., Xie Z., Hu J. Cloud shape classification system based on multi-channel cnn and improved fdm. *IEEE Access*. 2020. vol. 8. pp. 44111–44124.
13. Bakalos N., Rallis I., Doulamis N., Doulamis A., Protopapadakis E., Voulodimos A. Choreographic pose identification using convolutional neural networks. *11th International Conference on Virtual Worlds and Games for Serious Applications (VS-Games)*. IEEE, 2019. pp. 1–7.
14. Rani C.J., Devarakonda N. An effectual classical dance pose estimation and classification system employing convolution neural network–long shortterm memory (CNN-LSTM) network for video sequences. *Microprocessors and Microsystems*. 2022. vol. 95. no. 104651.
15. Yang Y., Yu D., Yang C. Video transaction algorithm considering fisco alliance chain and improved trusted computing. *PeerJ Computer Science*. 2021. vol. 7. no. e594.
16. Hu K., Jin J., Zheng F., Weng L., Ding Y. Overview of behavior recognition based on deep learning. *Artificial Intelligence Review*. 2023. vol. 56. no. 3. pp. 1833–1865.
17. Matsuyama H., Aoki S., Yonezawa T., Hiroi K., Kaji K., Kawaguchi N. Deep learning for ballroom dance recognition: A temporal and trajectory-aware classification model with three-dimensional pose estimation and wearable sensing. *IEEE Sensors Journal*. 2021. vol. 21. no. 22. pp. 25437–25448.
18. Ng L.H.X., Tan J.Y.H., Tan D.J.H., Lee R.K.-W. Will you dance to the challenge? predicting user participation of TikTok challenges. *Proceedings of the IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*. 2021. pp. 356–360.
19. He H., Luo Q. Online teaching mode of college sports dance course under the background of internet plus. *International Conference on Information Technology and Contemporary Sports (TCS)*. 2021. pp. 160–164.
20. Zhu X. Research on the application of digital media technology in sports dance teaching. *International Conference on Education, Information Management and Service Science (EIMSS)*. 2021. pp. 22–26.

21. Hu Z. Research on the application of virtual reality technology in the teaching of sports dance in colleges and universities. 2nd International Conference on Artificial Intelligence and Education (ICAIE). 2021. pp. 414–418.
22. Kritsis K., Gkiokas A., Pikrakis A., Katsourou V. Danceconv: Dance motion generation with convolutional networks. IEEE Access. 2022. vol. 10. pp. 44982–45000.
23. Chen Y., Li X. Research on the application of flipped classroom model in college sports dance teaching. International Conference on Information Technology and Contemporary Sports (TCS). 2021. pp. 508–511.
24. Li Y., Xu K. Online sports dance body contour extraction and training algorithm based on dsp chip intelligent high-definition camera image processing. 7th International Conference on Communication and Electronics Systems (ICCES). 2022. pp. 908–911.
25. Kaur M., Mohta A. A review of deep learning with recurrent neural network. International Conference on Smart Systems and Inventive Technology (ICSSIT). 2019. pp. 460–465.
26. Rallis I., Voulodimos A., Bakalos N., Protopapadakis E., Doulamis N., Doulamis A. Machine learning for intangible cultural heritage: a review of techniques on dance analysis. Visual Computing for Cultural Heritage. 2020. pp. 103–119.
27. Biswal A. Recurrent neural network (RNN) tutorial: Types, examples, LSTM and more. Simplilearn. Com. Retrieved. 2022. Available at: <https://www.simplilearn.com/tutorials/deep-learning-tutorial/rnn> (accessed: 05.10.2023).
28. Zargar S. Introduction to sequence learning models: RNN, LSTM, GRU. Department of Mechanical and Aerospace Engineering, North Carolina State University. 2021. DOI: 10.13140/RG.2.2.36370.99522.
29. Zhang W., Li H., Tang L., Gu X., Wang L., Wang L. Displacement prediction of jiu-xian-ping landslide using gated recurrent unit (gru) networks. Acta Geotechnica. 2022. vol. 17. no. 4. pp. 1367–1382.
30. Li W., Wei Y., An D., Jiao Y., Wei Q. LSTM-TCN: Dissolved oxygen prediction in aquaculture, based on combined model of long short-term memory network and temporal convolutional network. Environmental Science and Pollution Research. 2022. vol. 29. no. 26. pp. 39545–39556.

Хунг Нгуен Вьет — Ph.D., преподаватель, Восточноазиатский технологический университет; студент, факультет телекоммуникаций, Ханойский университет науки и технологий. Область научных интересов: мультимедийные коммуникации, сетевая безопасность, искусственный интеллект, проектирование трафика в сетях следующего поколения, гарантия качества сетевых услуг, экологически чистые сети, приложения. Число научных публикаций — 16. hungnv@eaut.edu.vn; Ки Фу - Ки Ань, Хатинь, Вьетнам; р.т.: +84(098)911-2079.

Лонг Тханг Куанг — научный сотрудник, Восточноазиатский технологический университет. Область научных интересов: приложения, сети. Число научных публикаций — 2. thangquangloi21@gmail.com; Суан Лонг, Йен Бинь, Йенбай, Вьетнам; р.т.: +84(084)6203-0902.

Бинь Нгуен Хай — преподаватель, факультет информационных технологий, Восточноазиатский технологический университет. Область научных интересов: мультимедийные коммуникации, системы управления базами данных, искусственный интеллект, приложения. Число научных публикаций — 1. binhnh@eaut.edu.vn; Чьен Тханг - Тхи Тран Суан Май, Тьонгми, Ханой, Вьетнам; р.т.: +84(090)627-8669.

Нгуен Тхи Туй Нга — преподаватель, факультет информационных технологий, Восточноазиатский технологический университет. Область научных интересов: мультимедийные коммуникации, системы управления базами данных, искусственный

интеллект, приложения. Число научных публикаций — 1. ngantt@eaut.edu.vn; Та Тхань Оай, Тханьчи, Ханой, Вьетнам; р.т.: +84(097)529-4770.

Хьонг Труонг Ту — Ph.D., Dr.Sci., заместитель начальника отдела, школа электротехники и электронной инженерии, Ханойский университет науки и технологий. Область научных интересов: сетевая безопасность, искусственный интеллект, проектирование трафика в сетях следующего поколения, гарантия качества сетевых услуг, экологичные сети и развитие экосистем Интернета вещей, приложений. Число научных публикаций — 90. huong.truongthu@hust.edu.vn; улица Дай Ко Вьет, 1, Ханой, Вьетнам; р.т.: +84(243)869-2242.

Луу Дук Лич — преподаватель, Университет науки и техники. Область научных интересов: управление динамикой транспортного средства, совместное вождение, прогнозирующее управление на основе моделей, сетевые системы управления. Число научных публикаций — 30. ldlich@dut.udn.vn; улица Нгуен Луонг Банга, 54, 550000, Дананг, Вьетнам; р.т.: +84(0236)384-2308.

A. ALSABRY, M. ALGABRI

ITERATIVE TUNING OF TREE-ENSEMBLE-BASED MODELS' PARAMETERS USING BAYESIAN OPTIMIZATION FOR BREAST CANCER PREDICTION

Alsabry A., Algabri M. Iterative Tuning of Tree-Ensemble-Based Models' parameters Using Bayesian Optimization for Breast Cancer Prediction.

Abstract. The study presents a method for iterative parameter tuning of tree ensemble-based models using Bayesian hyperparameter tuning for states prediction, using breast cancer as an example. The proposed method utilizes three different datasets, including the Wisconsin Diagnostic Breast Cancer (WDBC) dataset, the Surveillance, Epidemiology, and End Results (SEER) breast cancer dataset, and the Breast Cancer Coimbra dataset (BCCD), and implements tree ensemble-based models, specifically AdaBoost, Gentle-Boost, LogitBoost, Bag, and RUSBoost, for breast cancer prediction. Bayesian optimization was used to tune the hyperparameters of the models iteratively, and the performance of the models was evaluated using several metrics, including accuracy, precision, recall, and f1-score. Our results show that the proposed method significantly improves the performance of tree ensemble-based models, resulting in higher accuracy, precision, recall, and f1-score. Compared to other state-of-the-art models, the proposed method is more efficient. It achieved perfect scores of 100% for Accuracy, Precision, Recall, and F1-Score on the WDBC dataset. On the SEER BC dataset, the method achieved an accuracy of 95.9%, a precision of 97.6%, a recall of 94.2%, and an F1-Score of 95.9%. For the BCCD dataset, the method achieved an accuracy of 94.7%, a precision of 90%, a recall of 100%, and an F1-Score of 94.7%. The outcomes of this study have important implications for medical professionals, as early detection of breast cancer can significantly increase the chances of survival. Overall, this study provides a valuable contribution to the field of breast cancer prediction using machine learning.

Keywords: iterative tuning, tree ensemble-based models, bayesian optimization, breast cancer, machine learning.

1. Introduction. Machine learning (ML) has a crucial role in predicting breast cancer (BC) and offers several benefits, including early detection and diagnosis, improved accuracy, personalized risk assessment, handling complex interactions, reducing false positives and negatives, and enabling continuous learning and improvement. By analyzing a vast amount of medical data, including mammograms, MRI scans, and patient health records, ML algorithms can identify patterns that might indicate the early stages of BC, leading to more effective treatment and improved patient outcomes [1].

Traditional methods of BC prediction, such as the BC Risk Assessment Tool (BCRAT) and Breast and Ovarian Analysis of Disease Incidence and Carrier Estimation Algorithm (BOADICEA) models, have limitations in their predictive accuracy [2, 3]. However, ML models can achieve higher accuracy rates, which are significantly higher than those of traditional models [4].

Furthermore, ML models have the ability to consider a wide range of risk factors, such as genetic data, lifestyle factors, and medical history, providing personalized risk assessments for individuals. This can help stratify prevention strategies and customize clinical management for each patient. In addition, ML algorithms can identify complex interactions among multiple heterogeneous risk factors, capturing nonlinear relationships and interactions that traditional models may overlook. ML models also have the potential to reduce false positives and negatives in BC diagnoses, preventing unnecessary treatments for those wrongly diagnosed and ensuring timely treatment for those with the disease. Finally, ML models can continuously learn and improve over time as they are exposed to more data, which can result in improved predictive accuracy as they analyze more patient data and learn from previous predictions [5]. Tree ensemble-based models, such as AdaBoost, Gentle-Boost, LogitBoost, Bag, and RUSBoost, are powerful ML tools that can be used for a variety of tasks, including predicting BC. These models work by creating decision trees and making predictions based on iteratively improving the predictions [6].

Traditionally, hyperparameters are tuned using methods like grid search or random search, which involve trying out many different combinations of hyperparameters and selecting the one that performs best on a validation set. However, these methods can be computationally expensive and do not guarantee finding the optimal set of hyperparameters [7].

Bayesian hyperparameter tuning is a more sophisticated approach that treats hyperparameter tuning as a Bayesian optimization problem. It builds a probabilistic model of the objective function (i.e., the validation error as a function of the hyperparameters) and uses this model to select the most promising hyperparameters to try next. This approach can be more efficient than grid search or random search because it uses information from previous evaluations to make smarter decisions about what hyperparameters to try next [8].

1.1. Authors Contributions. This study makes a significant contribution to the field of BC prediction across different datasets. By applying Bayesian hyperparameter tuning to tree ensemble-based models through several iterations, the study aims to enhance the performance of the models and generalization capabilities for BC prediction in diverse datasets. The challenges of model adaptability and robustness are tackled in this study through systematic evaluation and assessment of various datasets. The findings of this study can provide valuable insights into the effectiveness and transferability of the proposed approach across various

BC datasets, contributing to the development of more reliable and versatile prediction models.

In the following sections, we will review relevant literature, describe the methodology employed in this study, present the experimental results, discuss the implications of our findings, and a comparative analysis is conducted to compare the results obtained from the proposed method to those of state-of-the-art models and to the findings of a literature review. By the end of this research, we will have provided valuable insights into the iterative tuning of tree ensemble-based models using Bayesian hyperparameter tuning for BC prediction.

2. Review of Literature. This literature review aims to investigate prior research on using ML for BC prediction, with a particular emphasis on tree-ensemble-based models. The review will also cover various tree ensemble-based models such as AdaBoost, GentleBoost, LogitBoost, Bag, and RUSBoost and their applications in BC prediction. Additionally, current approaches to hyperparameter tuning, such as grid search and Bayesian hyperparameter tuning, will be discussed. The objective of this review is to identify the most efficient tree-ensemble-based models and parameter tuning methods for BC prediction.

Table 1 serves as a comprehensive summary of the related works, providing a clear and concise overview of the studies analyzed in this research.

2.1. Previous studies on breast cancer prediction. The research objectives of previous studies regarding BC prediction were diverse. Some studies aimed to predict the presence or absence of BC, using the BCCD dataset. Other studies focused on classifying breast tumors as benign or malignant, utilizing the WDBC dataset. Additionally, some studies aimed to predict patient survival or death, and the SEER dataset was used for this purpose. In this section, we delve into the studies carried out for each of these datasets.

2.1.1. Studies Utilizing the WDBC Dataset in Prior Research. Numerous studies have utilized the WDBC dataset to assess various machine learning (ML) algorithms and techniques for binary classification. These studies have employed a diverse range of classification methods, including Support Vector Machine (SVM), Random Forest (RF), Extreme Learning Machine (ELM), and Naive Bayes. In some of these studies, optimization techniques were utilized to enhance the performance of the classification algorithms.

In one such study, [9] achieved the highest accuracy of 99.3% by utilizing an optimized SVM with Bayesian hyperparameter optimization.

This study exemplified the effectiveness of leveraging a well-established optimization technique to boost the classification algorithm's performance.

Table 1. Summary of the related works

Ref.	Year	Dataset	Methods / Techniques	Accuracy (%)
[10]	2019	WDBC	WQPSO with smooth SVM	98.42
[12]	2019	WDBC	SVM with 10 selected features	96.72
[13]	2020	WDBC	Optimized FSTBSVM with Jaya optimization techniques	94.36
[11]	2021	WDBC	Cloud-based ELM	98.68
[14]	2021	WDBC	SVM and RF	96.5
[9]	2022	WDBC	Optimized SVM with bayesian hyperparameter optimization	99.3
[15]	2019	SEER BC	Gradient Boosting with Genetic Algorithm	75.03
[16]	2020	SEER BC	Improved Random Forest - based rule extraction	80.5
[17]	2020	SEER BC	J48	93
[18]	2022	SEER BC	RF	94.6
[19]	2020	BCCD	GA and Gradient Boosting Classifier	79
[20]	2021	BCCD	Adaboost Classifier	80
[9]	2022	DCCD	polynomial SVM	76.9

Study [10] achieved an accuracy of 98.42% using Water Quality Prediction using Particle Swarm Optimization (WQPSO) with smooth SVM, indicating that the algorithms used in these studies are effective for the WDBC dataset.

Study [11] achieved an accuracy of 98.68% using cloud-based ELM, which is slightly higher than the accuracy achieved by [10]. ELM is a relatively new algorithm that has been shown to be effective for classification tasks, and this study demonstrated its usefulness for the WDBC dataset.

Study [12] achieved an accuracy of 96.72% using SVM with 10 selected features, which is slightly lower than the other studies. However, this study used feature selection techniques to identify the most relevant features, which can reduce the computational complexity of the classification models and improve their performance.

Study [13] achieved an accuracy of 94.36% using optimized FSTBSVM with Jaya optimization techniques, which is lower than the other studies. However, this study explored a relatively new technique for

classification and demonstrated its effectiveness in achieving high accuracy.

Study [14] examined the performances of six different classification algorithms and achieved an accuracy of 96.5% using SVM and RF. While this study did not achieve the highest accuracy, it provided a comprehensive evaluation of different algorithms' performances on the WDBC dataset.

The studies included in this comparison exhibited high accuracy in classifying the WDBC dataset. The performance of the classification model was considerably influenced by the selection of algorithm, technique, and feature selection. While study [9] achieved the highest accuracy by utilizing optimized SVM with Bayesian hyperparameter optimization, indicating its efficacy in classifying the WDBC dataset, other studies also attained high accuracy using different algorithms and techniques. These findings demonstrate the significance of exploring various methods for classification tasks.

2.1.2. Studies Utilizing the SEER BC Dataset in Prior Research.

Several other studies have concentrated on improving ML techniques to develop models for predicting the survival of BC patients using the SEER BC dataset. These studies employed different algorithms and techniques for classification, such as Gradient Boosting, RF, and J48 decision tree.

Study by [18] achieved the highest accuracy of 94.64% using RF, indicating the effectiveness of this algorithm for the SEER BC dataset. RF is a well-established algorithm for classification tasks, and its success in this study further emphasizes its utility for BC prediction tasks. Similarly, study by [17] achieved an accuracy of 93.02% using the J48 decision tree algorithm, demonstrating the effectiveness of Decision Tree (DT) algorithms for the SEER BC dataset.

In contrast, study [15] achieved the lowest accuracy of 75.03% using Gradient Boosting with Genetic Algorithm (GA). While this study demonstrated the potential of using optimization techniques to improve the performance of classification algorithms, it was not as effective as other studies in achieving high accuracy for the SEER BC dataset.

Study [16] explored a novel approach for rule extraction and classification, achieving an accuracy of 80.45%, which is lower than the accuracies achieved by the other studies. However, this study's approach has the potential to improve the accuracy of classification models, demonstrating the importance of exploring novel techniques in the field of BC prediction using ML.

In general, the studies presented in this revision achieved varying levels of accuracy in classifying the SEER BC dataset. The choice of

algorithm significantly affected the performance of the classification model. Studies [18] and [17] achieved high accuracy using well-known algorithms such as RF and J48, while study [16] explored a novel approach for rule extraction and classification.

2.1.3. Studies Utilizing the BCCD Dataset in Prior Research.

Similarly, several studies have explored the use of ML techniques in the development of models for BC diagnosis using the BCCD dataset. These studies have used different algorithms such as Adaboost, Gradient Boosting, and SVM, among others. They have also employed feature selection and optimization techniques to improve model performance.

Study [20] achieved the highest accuracy of 80% using the Adaboost Classifier. This study demonstrated the effectiveness of using Adaboost for the BCCD dataset, which is a well-known algorithm for classification tasks.

Study [19] achieved an accuracy of 79% using the Gradient Boosting Classifier with the Genetic Algorithm for feature selection. This study demonstrated the effectiveness of using feature selection techniques to identify the most relevant features for classification, which can reduce the computational complexity of the classification models and improve their performance.

Study [9] achieved an accuracy of 76.9% using a polynomial SVM, which is lower than the other studies. However, this study explored a different algorithm than Adaboost and Gradient Boosting and demonstrated the potential of using a polynomial SVM for the BCCD dataset.

Overall, the studies presented in this comparison achieved varying levels of accuracy in classifying the BCCD dataset. The choice of algorithm and technique significantly affected the performance of the classification model. Studies [20] and [19] achieved high accuracy using Adaboost and Gradient Boosting with GA for feature selection, respectively. Study [9] explored a different algorithm and achieved lower accuracy but demonstrated the potential of using a polynomial SVM for the BCCD dataset.

2.2. Existing tree ensemble-based models. This section focuses on reviewing the tree-ensemble-based models that exist, including AdaBoost, GentleBoost, LogitBoost, Bag, and RUSBoost, and their applications in breast cancer (BC) prediction. Each of these models possesses unique characteristics that can be effective for different datasets and objectives. A detailed description of each model and its algorithm will be presented. Additionally, we will examine the applications of these models in BC prediction, including their performance on different datasets and feature selection. The objective of this section is to offer insights into the strengths

and weaknesses of each model and identify the most effective models for BC prediction.

2.2.1. Bagged Trees. It is an ML ensemble meta-algorithm designed to improve the stability and accuracy of ML algorithms used in statistical classification and regression. The algorithm was first introduced by Breiman in 1996 and has since been widely used in various applications such as text classification, image classification, and bioinformatics [21].

The basic idea behind bagging is to generate multiple versions of a predictor and use these to get an aggregated predictor. The aggregation averages usually over the predictions for regression problems and does a majority vote for classification problems. The Bagged Trees algorithm has several advantages. Firstly, it can reduce overfitting and improve the generalization performance of the model. Secondly, it is robust to noise and outliers in the data. Finally, it can handle high-dimensional feature spaces and large datasets. However, Bagged Trees have some limitations. One of the main limitations is that it can be computationally expensive, especially when the number of trees in the ensemble is large. Additionally, the interpretability of the model is reduced as the number of trees increases. Finally, the quality of the predictions can be affected by the choice of hyperparameters such as the number of trees, the depth of each tree, and the size of the bootstrap samples [22, 23].

The process of Bagged Trees can be described as follows [22].

Algorithm 1. Bagging algorithm when applied to decision trees for a classification problem

Initialize: Determine the number of bootstrap samples, B , to be created.

For $b = 1$ to B , repeat steps 1-3:

Step 1. Bootstrap Sampling: Create a bootstrap sample by randomly selecting N instances from the original dataset with replacement, where N is the size of the dataset.

Step 2. Tree Building: Build a decision tree based on the bootstrap sample. Grow the tree to maximum size and do not perform any pruning.

Step 3. End of the loop: Return to step 2 and repeat the process until B trees have been grown.

Prediction: For a new data point, make a prediction with each of the B trees. The final prediction is the class that gets the most votes among the B trees.

Several studies have investigated the efficacy of the bagged trees algorithm for BC classification. However, there are variations in the datasets utilized and the accuracy achieved by these studies.

One study [24] applied the SMOTE technique for oversampling the data acquired from Shengjing Hospital of China Medical University. The study used the Bagged Tree algorithm and achieved an accuracy of 70.3%.

Another study [25] investigated a supervised learning technique for classifying BC using four different classifiers, namely Boosted Tree, Bagged Tree, Logistic Regression (LR), and Artificial Neural Networks (ANN). The ANN outperformed the other classifiers with an accuracy of 97.56%, while the bagged tree achieved the second-best accuracy. This study highlights the effectiveness of the ANN and bagged tree in classifying BC and demonstrates the importance of comparing multiple classifiers to identify the best-performing one.

In a third study [26], the performance of the bagged trees algorithm was evaluated on a dataset of 23 attributes containing 575 samples obtained from the Mizoram State Cancer Institute of Aizawl, Mizoram, India. An accuracy of 82.5% was achieved, which is higher than the first study but lower than the second study. However, the study was limited by the small size of the dataset, which may affect the generalization of the results.

2.2.2. Adaboost Trees. It is a variant of AdaBoost, which uses DT as a weak classifier. In each iteration, a DT is trained on the weighted samples, and the weights are updated based on the misclassification rate. The final prediction is made by combining the predictions of all the DTs, typically by taking the weighted average.

Studies have widely used the Adaboost algorithm for BC classification. For example, in [27], the performance of DT and Adboost was evaluated on an imbalanced dataset such as WDBC. Both models achieved high accuracy, with DT achieving 88.8% and Adboost achieving 92.5%. The study highlights the importance of selecting appropriate models for imbalanced datasets, such as Adboost, which is designed to handle such datasets, and demonstrates its efficacy in classifying BC.

In another study [28], ten models, including Adboost, RF, Tree, Gradient Boosting, KNN, ANN, Naïve Bayes, SVM, LR, and SGD, were compared for their performance in BC classification. Adboost achieved the best performance with an accuracy of 98.3%, an f1-score of 98.3%, a precision of 98.4%, a recall of 98.3%, and an AUC of 99.9%. The other models achieved varying levels of accuracy, with RF achieving 88.7%, Tree achieving 89.0%, Gradient Boosting achieving 86.3%, KNN achieving 77.3%, ANN achieving 74.7%, Naive Bayes achieving 71.7%, SVM achieving 73.7%, LR achieving 73.0%, and SGD achieving 71.3%. The study demonstrates the importance of comparing multiple models and selecting the best-performing one for BC classification.

The algorithm for AdaBoost classification is described as follows [29].

Algorithm 2. Real AdaBoost

Initialize: Start with weights $w_i = 1/N$, $i = 1, 2, \dots, N$.

For $m = 1, 2, \dots, M$, repeat steps 1-3:

Step 1: Fit the classifier to obtain a class probability estimate $p_m(x) = p_w^{\wedge}(y=1/x) \in [0,1]$, using weights w_i on the training data.

Step 2: Set $f_m(x) \leftarrow \frac{1}{2} \log p_m(x) / (1-p_m(x)) \in R$.

Step 3: Set $w_i \leftarrow \exp[-y_i f_m(x_i)]$, $i = 1, 2, \dots, N$, and renormalize so that $\sum_i w_i = 1$.

Output the classifier $\text{sign} \left[\sum_{m=1}^M f_m(x) \right] = 1$

2.2.3. GentleBoost Trees. It is an ML method used to improve the performance of DTs on binary classification problems. GentleBoost is known for its robustness and simplicity, and it is particularly effective when dealing with noisy data or outliers.

The GentleBoost algorithm works by iteratively adding weak classifiers (in this case, decision trees) to the model in a way that minimizes the overall error.

The algorithm for GentleBoost classification is described as follows [29].

Algorithm 3. GentleBoost

Initialize: Start with weights $w_i = 1/N$, $i = 1, 2, \dots, N$, $F(x) = 0$.

For $m = 1, 2, \dots, M$, repeat steps 1-3:

Step 1: Fit the regression function $f_m(x)$ by *weighted least-squares* of y_i to x_i with weight w_i .

Step 2: Update $F(x) \leftarrow F(x) + f(x)$.

Step 3: Update $w_i \leftarrow w_i \exp[-y_i f_m(x_i)]$ renormalize.

Output the classifier $\text{sign} [F(x)] = \text{sign} \left[\sum_{m=1}^M f_m(x) \right]$.

2.2.4. LogitBoost Trees. It is a boosting algorithm used for binary classification problems. It was introduced by Jerome Friedman, Trevor Hastie, and Robert Tibshirani in 1998 [29]. The algorithm is based on additive logistic regression and uses decision trees as base learners. The main idea behind LogitBoost is to iteratively fit a simple model (like a decision stump) to the current residuals, then add this model to the ensemble, and update the residuals. The process is repeated until a stopping criterion is met.

The LogitBoost algorithm has several advantages. Firstly, it can handle noisy and complex datasets and achieve high accuracy. Secondly, it is robust to overfitting and can generalize well to new data. Finally, it is computationally efficient and can handle large datasets. However, LogitBoost also has some limitations. One of the main limitations is that it can be sensitive to outliers in the data. Additionally, the quality of the predictions can be affected by the choice of hyperparameters such as the number of weak classifiers and the learning rate.

The LogitBoost algorithm was utilized for BC classification and showed significant results compared to other methods; i.e., Study [30] compared the performance of several ML models in classifying tumors as metastatic or non-metastatic using two different datasets (Vijver dataset and Wang dataset). The study evaluated the performance of Logitboost, LR, SVM, Tree, Adaboost, and RF models. The results showed that the performance of the models varied depending on the dataset used. With the Vijver's dataset, the models achieved moderate to good accuracy, with Logitboost achieving the highest accuracy of 79% and an AUC of 0.810. SVM attained commendable results in terms of accuracy and AUC values, achieving an accuracy rate of 77.1% and an AUC of 0.806. Adaboost also performed well, achieving an accuracy of 77.7% and an AUC of 0.782. However, the accuracy and AUC values of the other models were relatively lower. With the Wang dataset, the models achieved higher accuracy and AUC values, with Logitboost achieving the highest accuracy of 89.7% and an AUC of 0.923. RF achieved high accuracy and AUC values, with an accuracy of 87.6% and an AUC of 0.915. Adaboost performed well, achieving an accuracy of 86.3% and an AUC of 0.893. SVM and Tree also achieved moderate to good accuracy and AUC values, while LR achieved relatively lower accuracy and AUC values. The results suggest that Logitboost, SVM, RF, and Adaboost are effective models for the Wang dataset, while Logitboost, SVM, and Adaboost are effective models for the Vijver dataset. However, it is important to consider the limitations of the study, such as the relatively small sample sizes and limited number of features used in the datasets.

The algorithm for LogitBoost classification is described as follows [29].

Algorithm 4. LogitBoost

Initialize: Start with weights $w_i = 1/N$, $i = 1, 2, \dots, N$, $F(x) = 0$ and probability estimates $p(x_i) = \frac{1}{2}$.

For $m = 1, 2, \dots, M$, repeat steps 1-3:

Step 1: Compute the working response and weights

$$Z_i = \frac{(y_i - P(x_i))}{P(x_i)(1 - P(x_i))}$$

Step 2: Fit the function $f(x)$ by a weighted least-square regression of Z_i to x_i using weights w_i .

Step 2: update $F(x) \leftarrow F(x) + \frac{1}{2} f_m(x)$ and $P(x) \leftarrow (e^{F(x)}) / (e^{F(x)} + e^{-F(x)})$.

Output the classifier $\text{sign}[F(x)] = \text{sign}[\sum_{m=1}^M f_m(x)]$.

2.2.5. RUSBoost Trees. It is a hybrid ML algorithm that combines Random Under-Sampling (RUS) and AdaBoost to handle imbalanced data classification problems. It was proposed in study [31] in 2010. The algorithm is designed to improve the performance of AdaBoost on imbalanced datasets by integrating a data sampling strategy. The RUSBoost algorithm exhibits several strengths. Primarily, it is capable of managing imbalanced datasets and achieving exceptional accuracy for the minority class. Moreover, it is resilient to overfitting and can generalize effectively to novel data. Lastly, it is computationally efficient and can handle sizable datasets. Despite these advantages, RUSBoost has certain drawbacks. Foremost among these is its susceptibility to noise and outliers in the data. Additionally, the quality of its predictions can be affected by hyperparameter selection, such as the number of weak classifiers and the size of the randomly selected negative class samples.

RUSBoost and SMOTE are used by several studies to handle imbalanced datasets; i.e., Study [32] aimed to examine the performance of two methods, RUSBoost and SMOTE-Boosted C5.0, for handling the problem of an imbalanced WDBC dataset for the classification of BC. The results showed that RUSBoost outperformed SMOTE-boosted C5.0 in terms of accuracy, sensitivity, and specificity. With RUSBoost, the study achieved an accuracy of 94.4%, a sensitivity of 93%, and a specificity of 95.4%. On the other hand, with SMOTE-Boosted C5.0, the study achieved

an accuracy of 92.5%, a sensitivity of 93.9%, and a specificity of 91.15%. These results suggest that RUSBoost is a more effective method for handling the imbalanced dataset in this context.

The algorithm for RUSBoost classification is described as follows [31].

Algorithm 5. RUSBoost

Given: Set S of examples $(x_1, y_1), \dots, (x_m, y_m)$ with minority class $y^f \in Y, |Y| = 2$

Weak learner, *WeakLearn*

Number of iterations, T

The desired percentage of total instances to be represented by the minority class,

N

Initialize: $D_1(i) = \frac{1}{m}$ for all i .

Do For $t = 1, 2, \dots, T$, **repeat steps 1-7:**

Step 1: Create a temporary training dataset S'_t with distribution D'_t using random undersampling.

Step 2: Call *WeakLean*, providing it with example S'_t and their weights D'_t .

Step 3: Get back a hypothesis $h_t: X \times Y \rightarrow [0, 1]$.

Step 4: Calculate the pseudo-loss (for S and D_t):

$$\epsilon_t = \sum_{(i,y): y_i \neq y} D_t(i)(1 - h_t(x_i, y_i) + h_t(x_i, y_i)).$$

Step 5: Calculate the weight update parameter:

$$\alpha_t = \frac{\epsilon_t}{1 - \epsilon_t}.$$

Step 6: Update D_t :

$$D_{t+1} = D_t(i) \alpha_t^{\frac{1}{2} (1 + h_t(x_i, y_i) - h_t(x_i, y_i; y_i \neq y))}$$

Step 7: Normalize D_{t+1} : Let $Z_t = \sum_i D_{t+1}(i)$.

$$D_{t+1}(i) = \frac{D_{t+1}(i)}{Z_t}$$

Output the final hypothesis: $H(x) = \operatorname{argmax}_{y \in Y} \sum_{t=1}^T h_t(x_i, y_i) \log \frac{1}{\alpha_t}$.

2.3. Current methods of parameter tuning. Parameter tuning is a crucial step in the process of building an ML model. It involves selecting the optimal values for the parameters of a model to improve its performance. The current methods of parameter tuning can be broadly categorized into Grid search and Bayesian optimization.

2.3.1. Grid Search. It is a traditional method for hyperparameter tuning. It involves specifying a subset of the hyperparameter space as a grid, and then systematically checking every point in the grid. For each combination of parameters, the model is trained, and its performance is measured. The main disadvantage of grid search is that it can be computationally expensive, especially for models with a large number of parameters. The following presents several studies that investigated the use of grid search to improve the performance of various ML models [33 – 36].

In study by [33], the authors employed grid search to fine-tune the hyperparameters of nine ML models, including Naive Bayes, LR, SVM, LASSO, DT, KNN, RF, AdaBoost, and XGBoost. The objective of the study was to identify which algorithms perform best for both balanced and imbalanced datasets. The results indicated that RF and XGBoost outperformed the other algorithms when the data was less balanced, whereas SVM, LR, and LASSO performed better than the other algorithms when the data was balanced. This finding highlights the importance of selecting the appropriate ML algorithm based on the dataset's balance or imbalance.

Another study [34] utilized grid search to optimize the hyperparameters of the SVM algorithm for BC classification. The authors compared the performance of SVM with and without grid search and found that grid search significantly improved the recall and precision of the SVM algorithm. The recall and precision were 83% and 61%, respectively, without grid search, while they were 95% and 95%, respectively, with grid search. This result suggests that hyperparameter tuning using grid search can enhance the performance of SVM for BC classification.

Similarly, study [35] employed grid search to optimize the hyperparameters of the RF algorithm for BC classification. The authors compared the performance of RF with and without grid search and found that grid search improved the recall, precision, and F1 score of the RF algorithm. The recall, precision, and F1 scores were 96% without grid search, while they were 97% with grid search. This result supports the effectiveness of hyperparameter tuning using grid search in enhancing the performance of ML algorithms in various applications.

Finally, study [36] used grid search to optimize the hyperparameters of the KNN algorithm for BC classification. The authors compared the performance of KNN with grid search and default tuning and found that grid search significantly improved the accuracy of the KNN algorithm. The accuracy was 94.35% with grid search, while it was 90.10% with default tuning. This result emphasizes the importance of hyperparameter tuning

using grid search in improving the performance of KNN for BC classification.

These studies demonstrate the effectiveness of hyperparameter tuning using grid search in enhancing the performance of ML algorithms for BC classification. The results highlight the importance of selecting the appropriate algorithm and tuning the hyperparameters for the specific dataset.

2.3.2. Bayesian Optimization. It is a more advanced method for hyperparameter tuning. It builds a probabilistic model of the function mapping from hyperparameter values to the objective evaluated on a validation set. By using this model, the algorithm can choose the most promising hyperparameters to evaluate in the true objective function. This method is more efficient than grid search and random search, especially for high-dimensional hyperparameter spaces [7, 37, 38].

Several studies have investigated the use of Bayesian optimization to enhance the performance of various ML models. In one study [7], a comprehensive comparative analysis was conducted on different ML models using various hyperparameter optimization methods, including Bayesian, grid search, and random search optimization. The findings revealed that the Bayesian hyperparameter optimization method was more stable than grid search and random search methods. Additionally, the XGBoost algorithm achieved a high accuracy of 94.74% and a sensitivity of 93.69%. In another study [37], a hybrid feature selection approach was implemented along with Bayesian hyperparameter tuning, resulting in the Extra tree classifier algorithm achieving the best accuracy of 96.2%. In a third study [38] a performance comparison was conducted on several ML algorithms, including SVM, DT, Naive Bayes, KNN, and Ensemble Classifiers, and the Bayesian optimization algorithm was applied to all classifiers to maximize the prediction accuracy. The results showed that the Bayesian optimization-based KNN algorithm outperformed the other ML algorithms, achieving an accuracy of 95.833%. Overall, these studies demonstrate the importance of selecting the appropriate optimization method and tuning hyperparameters to improve the performance of ML algorithms.

2.4. Research gap. The literature has shown that the performance of machine learning models heavily relies on the selection of appropriate hyperparameters. While several studies have investigated the use of various optimization methods to tune these hyperparameters, there is a research gap in exploring the potential benefits of Bayesian hyperparameter optimization for iterative tuning of Tree-Ensemble-Based machine learning models.

Tree-Ensemble-Based models, such as AdaBoost, Gentle-Boost, LogitBoost, Bag, and RUSBoost, are commonly used in various applications, including classification and regression tasks. However, the optimal hyperparameters for these models are not always known and can be challenging to determine given the large number of possible combinations.

Bayesian optimization is a promising approach for hyperparameter tuning that has been shown to outperform other optimization techniques in various applications. However, to the best of our knowledge, there is no investigation in the literature that explores the use of Bayesian hyperparameter optimization for iterative tuning of Tree-Ensemble-Based machine learning models.

Therefore, the research gap in the literature is the lack of studies that investigate the potential benefits and limitations of using Bayesian hyperparameter optimization for iterative tuning of Tree-Ensemble-Based machine learning models, such as AdaBoost, Gentle-Boost, LogitBoost, Bag, and RUSBoost. This research gap highlights the need for further exploration of this approach to improve the performance of these models in various applications.

3. Methodology. The aim of this study is to develop an iterative machine learning approach based on tree ensemble-based models with Bayesian hyperparameter tuning. The methodology involves the following steps.

3.1. Data collection and preparation. This study utilized three BC datasets, namely the WDBC, BCCD and the SEER BC dataset. The WDBC, BCCD, and SEER BC datasets are distinct from one another and have been utilized for different classification purposes, rather than being employed for the same classification task. Therefore, these datasets do not intersect. In the case of the WDBC dataset, the target class is labeled as "classification" and pertains to determining whether a tumor is malignant or benign, as presented in Table 2. On the other hand, the BCCD dataset assigns the target class as "Diagnosis," indicating the presence or absence of breast cancer, as specified in Table 3. Lastly, the SEER breast cancer dataset employs a target class called "STATUS," which indicates whether the patient is alive or deceased, as described in Table 4.

WDBC dataset is a well-known dataset used for breast cancer classification tasks. It contains 569 samples, each of which corresponds to a breast mass detected in a patient. Each sample is described by 30 different features, which provide information about the characteristics of the mass [39]. Table 2 shows a brief description of each feature in the dataset.

Table 2. WDBC dataset description

No.	Feature	Description
1	radius_mean	The mean radius of the mass
2	texture_mean	The mean texture of the mass.
3	perimeter_mean	The mean perimeter of the mass
4	area_mean	The mean area of the mass
5	smoothness_mean	The mean smoothness of the mass
6	compactness_mean	The mean compactness of the mass
7	concavity_mean	The mean concavity of the mass
8	concave points_mean	The mean number of concave points on the mass
9	symmetry_mean:	The mean symmetry of the mass
10	fractal_dimension_mean	The mean fractal dimension of the mass
11	radius_se	The standard error of the radius of the mass
12	texture_se	The standard error of the texture of the mass
13	perimeter_se	The standard error of the perimeter of the mass
14	area_se	The standard error of the area of the mass
15	smoothness_se	The standard error of the smoothness of the mass
16	compactness_se	The standard error of the compactness of the mass
17	concavity_se	The standard error of the concavity of the mass
18	concave points_se	The standard error of the number of concave points on the mass
29	symmetry_se	The standard error of the symmetry of the mass
20	fractal_dimension_se	The standard error of the fractal dimension of the mass
21	radius_worst	The worst (largest) radius of the mass
22	texture_worst	The worst (most irregular) texture of the mass
23	perimeter_worst	The worst (largest) perimeter of the mass
24	area_worst	The worst (largest) area of the mass
25	smoothness_worst	The worst (least smooth) smoothness of the mass
25	compactness_worst	The worst (most compact) compactness of the mass
26	concavity_worst	The worst (most severe) concavity of the mass
27	concave points_worst	The worst (most severe) number of concave points on the mass
28	symmetry_worst	The worst (least symmetrical) symmetry of the mass
29	fractal_dimension_worst	The worst (most irregular) fractal dimension of the mass
30	Classification	Malignant (cancerous) or benign (non-cancerous)

BCCD is a dataset used for BC classification tasks. It contains 116 (64 patients and 52 healthy controls) samples, each of which corresponds to

a breast mass detected in a patient. Each sample is described by 10 different features, which provide information about the characteristics of the mas [40]. Table 3 shows a brief description of each feature in the dataset.

Table 3. BCCD dataset description

No.	Feature	Description
1	Age	The age of the patient at the time of diagnosis
2	BMI	The body mass index of the patient
3	Glucose	The fasting plasma glucose concentration of the patient
4	Insulin	The fasting serum insulin level of the patient
5	HOMA	The homeostasis model assessment (HOMA) index, which estimates insulin resistance
6	Leptin	The concentration of leptin, a hormone involved in regulating energy balance
7	Adiponectin	The concentration of adiponectin, a hormone involved in regulating glucose levels
8	Adiponectin	The concentration of resistin, a hormone involved in regulating insulin sensitivity
9	MCP-1	The concentration of monocyte chemoattractant protein-1, a cytokine involved in inflammation and immune response
10	Diagnosis	Presence or absence of breast cancer


The SEER BREAST CANCER dataset is a dataset used for survival analysis tasks of breast cancer patients. It contains information on patients diagnosed with breast cancer between 2006 and 2010 and includes 4024 instances, of which 3408 are alive and 616 are deceased. Each instance is described by 15 different features, which provide information about the characteristics of the patients and their cancer [41]. Table 4 shows a brief description of each feature in the dataset:

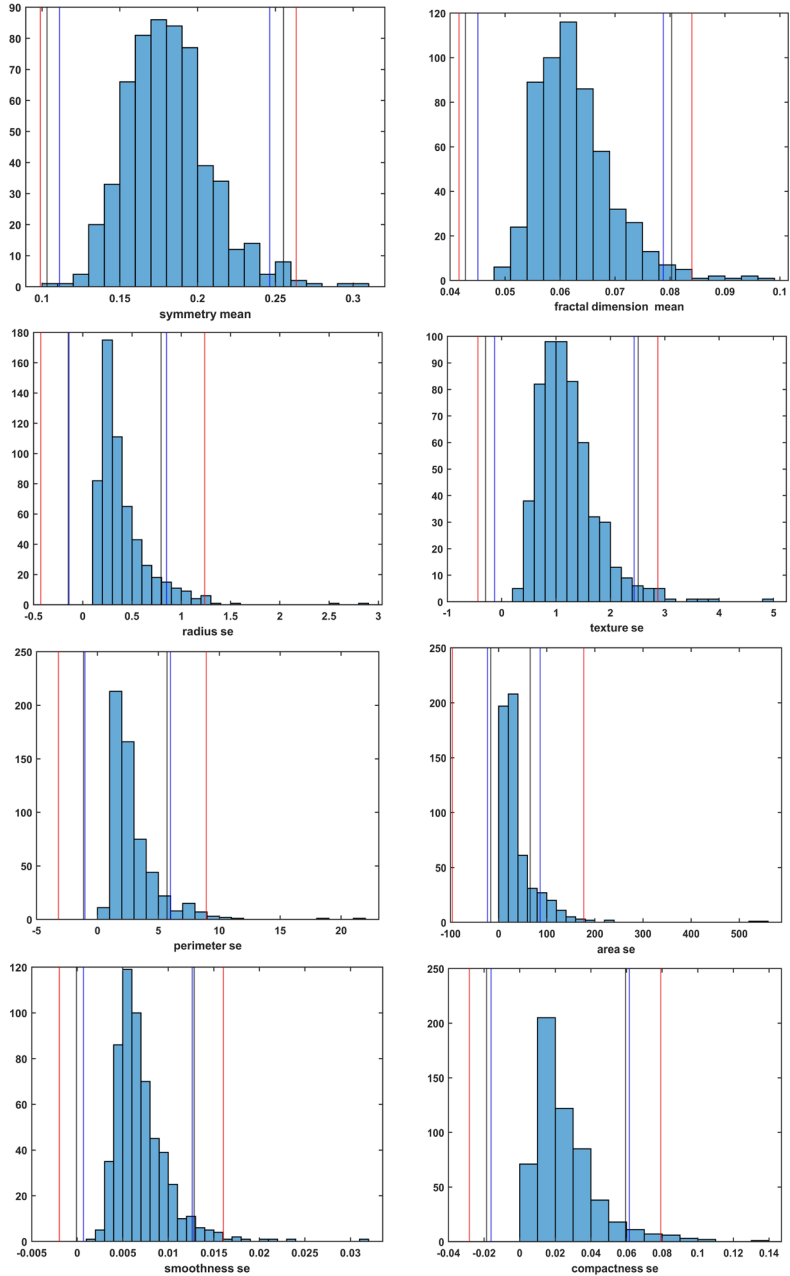
To prepare the datasets for analysis, the study used several preprocessing techniques. One of the preprocessing techniques used is the Synthetic Minority Over-sampling Technique (SMOTE) to address the imbalance problem that was obvious in the three datasets. SMOTE generates synthetic samples for the minority class to balance the dataset and improve the performance of the classification models.

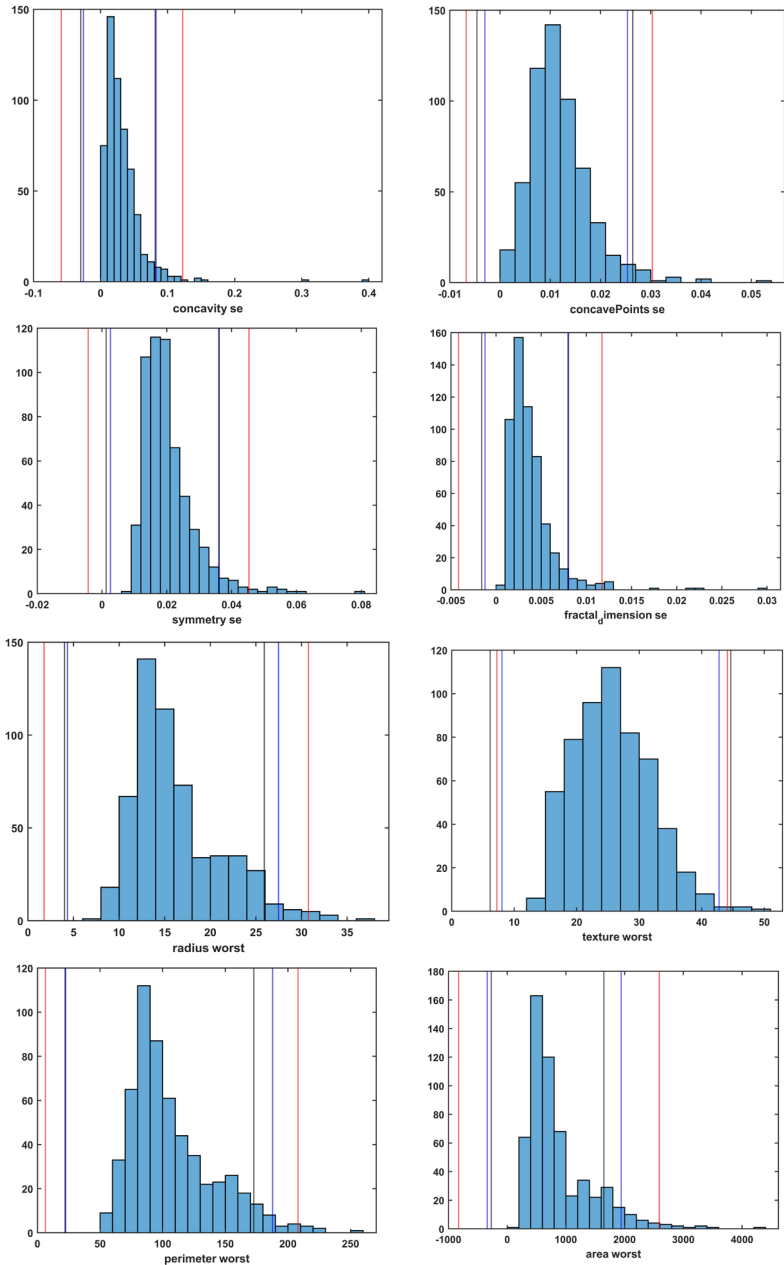
Table 4. SEER BC dataset description

No.	Feature	Type
1	AGE	The age of the patient at the time of diagnosis
2	RACE	The race of the patient
3	MARITAL STATUS	The marital status of the patient
4	T STAGE	The size and extent of the primary tumor at diagnosis
5	N STAGE	The spread of cancer to nearby lymph nodes at diagnosis
6	6TH STAGE	The stage of the cancer at diagnosis, based on the TNM system
7	GRADE	The grade of the tumor, indicating how abnormal the cancer cells look under a microscope
8	A STAGE	The stage of the cancer at diagnosis, based on a different staging system
9	TUMOR SIZE	The size of the tumor at diagnosis, in millimeters
10	ESTROGEN STATUS	The status of the estrogen receptor in the tumor
11	PROGESTERONE STATUS	The status of the progesterone receptor in the tumor
12	REGIONAL NODES EXAMINED	The number of lymph nodes examined during surgery
13	REGIONAL NODES POSITIVE	The number of lymph nodes with cancer cells found during surgery
14	SURVIVAL MONTHS	The number of months between diagnosis and last follow-up or death
15	STATUS (classification)	Alive or Dead

Additionally, the study removed outliers from the WDBC and SEER BC datasets using the method of three standard deviations (3 SD) above and below the mean. This method removes extreme data points that may skew the analysis or modeling results. Figures 1, 2 display a comparative analysis of three distinct outlier detection techniques. The first technique employed in the analysis is the three standard deviations (3-SD) above and below the mean, which are depicted in red. The second technique involves 1.5 times the interquartile range (IQR) above or below the third and first quartiles and is represented by a blue color. The third technique is based on three scaled median absolute deviations above and below the median and is displayed in black.







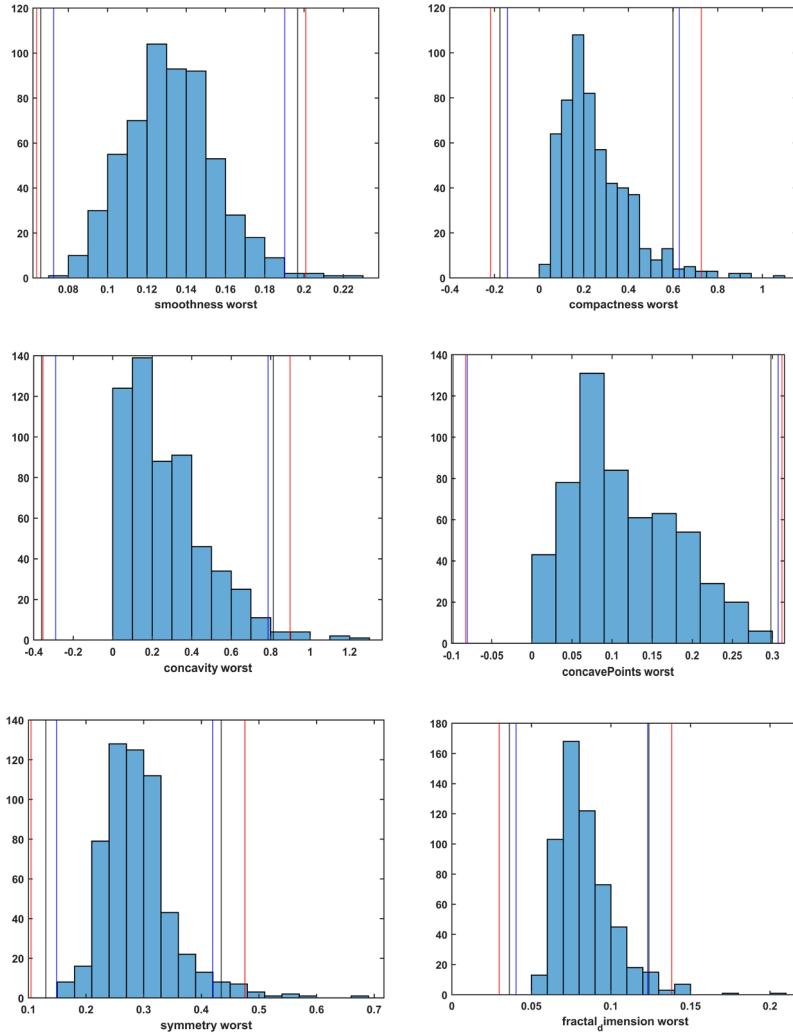


Fig. 1. Outlier detection techniques for the WDBC dataset

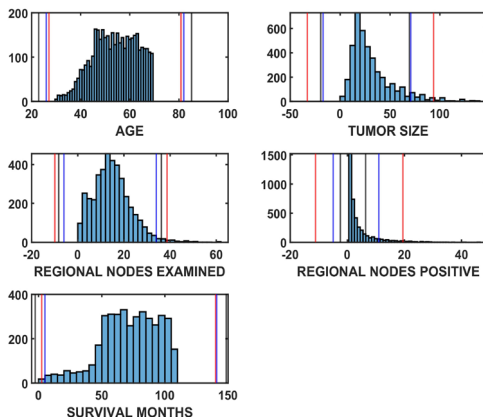


Fig. 2. Outlier detection techniques for the SEER dataset

3.2. The proposed iterative process. The study used five tree ensemble-based models: AdaBoost, GentleBoost, LogitBoost, Bag, and RUSBoost. Each model was trained with the default hyperparameters and with iterative tuning using Bayesian hyperparameters tuning. Figure 3 shows the workflow of the proposed iterative training process while the iterative tuning process involved the following steps.

Algorithm 6. Steps of iterative tuning process

Let i be the number of the models i [1,2,3,4,5].

Let N be the number of iterations.

Step 1. Split the dataset into training and validation sets.

Step 2. Train the model $_i$ with the default hyperparameters on the training set and evaluate its performance on the validation set.

Step 3. Use Bayesian hyperparameters tuning to select the best hyperparameters for the model based on the performance on the validation set.

Step 4. Train the model with the selected hyperparameters on the training set and evaluate its performance on the validation set.

Step 5. Repeat the above steps until the performance on the validation set no longer improves or a maximum number of iterations is reached.

Step 6. Repeat the above steps until the performance on the validation set no longer improves or a maximum number of iterations is reached.

Step 7. If the performance of model $_i$ best than model $_{i-1}$ then set the best result = the performance of model $_i$.

Step 8. Repeat steps 1-7 for all i .

Step 9. Repeat steps 1-7 for N iteration.

Output The final prediction result including the Method name, best performance metrics, and the optimal hyperparameters.

3.3. Evaluation. The performance evaluation of each ML model in the study is conducted based on their effectiveness in predicting the target class. To assess their performance, a range of metrics, including accuracy, precision, recall, and F1-score, are employed. These metrics provide a comprehensive evaluation of the predictive capabilities and overall performance of the ML models. The calculation details of these evaluation metrics can be found in Table 5, which illustrates how each metric is computed and provides further insights into the model performance.

Table 5. Evaluation Metrics Equations

Measure	Equation
Accuracy	$(TP+TN)/(TP+TN+FN+FP)$
Precision	$TP/(TP+FP)$
Recall	$TP/(TP+FN)$
F1 score	$(2 \times \text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall})$




Fig. 3. Iterative tuning workflow

4. Result and Discussion. The experiments were conducted on three different datasets: WDBC, SEER BC, and BCCD. In the case of the WDBC dataset, the results showed that Gentle-Boost and AdaBoost achieved the highest accuracy of 100% across multiple iterations. These algorithms outperformed other models such as LogitBoost, which achieved an accuracy of 99.1%, Bagged trees with 98.2% accuracy, and RUSBoost with 95.5% accuracy. The detailed results can be found in Table 6. Moving on to the SEER BC dataset, Gentle-Boost demonstrated superior performance compared to the other models in all experiments with varying iterations. It consistently outperformed the rest and achieved the highest accuracy of 96% with 100 iterations. These findings are presented in Table 8. For the BCCD dataset, the Bagged trees algorithm stood out by achieving the highest performance. It attained an accuracy of 94.7% in the case of 60 iterations. The detailed results for this dataset can be found in Table 10.

4.1. Discussion of the results obtained by implementing the proposed framework on the WDBC. Table 6 shows the best accuracy achieved by the proposed iterative tuning of the tree ensemble-based model using Bayesian hyperparameter tuning. The results displayed in Table 7 show the performance of several tree ensemble-based algorithms applied to the WDBC dataset for different numbers of iterations. The results show that the various tree ensemble-based algorithms achieve very high accuracy, precision, recall, and F1-score values, indicating that they are generally effective in classifying the WDBC dataset. The Gentle-Boost algorithm appears to be the most effective, achieving the highest performance in six of the 12 cases, including the highest accuracy and F1-score values for 10, 30, 40, 60, 90, 110, and 100 iterations. AdaBoost also performed well, achieving the highest performance for 20 and 80 iterations. LogitBoost achieved the highest performance over 70 iterations, whereas RUSBoost achieved the highest performance over 50 iterations. Finally, the Bagged trees algorithm achieved the highest performance for 120 iterations. The performance of the different algorithms varied depending on the number of iterations. For example, AdaBoost achieved the highest performance for 20 and 80 iterations, but its performance was not as good for other numbers of iterations. Similarly, RUSBoost achieved the highest performance for 50 iterations, but its performance dropped sharply for higher or lower numbers of iterations. Overall, the results suggest that the Gentle-Boost algorithm is robust and effective for classifying the WDBC dataset. However, the choice of algorithm may depend on the specific application and the number of iterations required.

Table 6. The accuracy achieved in different numbers of iterations of the WDBC dataset

No. Iteration	AdaBoost	GentleBoost	LogitBoost	Bagged trees	RUSBoost
10 Iteration	-	100	-	-	-
20 Iteration	100	-	-	-	-
30 Iteration	-	99.1	-	-	-
40 Iteration	-	99.1	-	-	-
50 Iteration	-	-	-	-	95.5
60 Iteration	-	99.1	-	-	-
70 Iteration	-	-	99.1	-	-
80 Iteration	99.1	-	-	-	-
90 Iteration	-	99.1	-	-	-
100 Iteration	-	100	-	-	-
110 Iteration	-	100	-	-	-
120 Iteration	-	-	-	98.2	-

Table 7. Evaluation of the performance of the proposed framework applied to the WDBC dataset

No. Iteration	Model	Evaluation Metrix			
		Accuracy	Precision	Recall	F1-Score
10 Iteration	GentleBoost	100	100	100	100
20 Iteration	AdaBoost	100	100	100	100
30 Iteration	GentleBoost	99.1	100	98.3	99.1
40 Iteration	GentleBoost	99.1	100	98.3	99.1
50 Iteration	RUSBoost	95.5	94.3	96.6	95.4
60 Iteration	GentleBoost	99.1	100	98.3	99.1
70 Iteration	LogitBoost	99.1	100	98.3	99.1
80 Iteration	AdaBoost	99.1	100	98.3	99.1
90 Iteration	GentleBoost	99.1	100	98.3	99.1
100 Iteration	GentleBoost	100	100	100	100
110 Iteration	GentleBoost	100	100	100	100
120 Iteration	Bagged trees	98.2	100	96.6	98.3

4.2. Discussion of the results obtained by implementing the proposed framework on the SEER BC dataset. Table 8 shows the best accuracy, whereas Table 9 displays the performance achieved by the proposed methodology applied to the SEER BC dataset for different numbers of iterations. The results show that the Gentle-Boost algorithm achieves high accuracy, precision, recall, and F1-score values, indicating that it is effective for classifying the SEER BC dataset. It is interesting to note that the performance of the Gentle-Boost algorithm is consistently high across all different numbers of iterations. In particular, the algorithm achieved the highest performance in all 12 cases, with an accuracy ranging from 90.1% to 96%, a precision ranging from 96.4% to 98%, a recall ranging from 93.8% to 94.2%, and an F1-score ranging from 95% to 96%. Compared with the results obtained for the WDBC dataset, the performance of the Gentle-Boost algorithm for the SEER BC dataset was generally lower. This is likely due to the fact that the SEER BC dataset is more complex and noisier than the WDBC dataset. In general, the results suggest that the Gentle-Boost algorithm is effective for classifying the SEER BC dataset, and that its performance is consistent across different numbers of iterations.

Table 8. The accuracy achieved in different numbers of iterations of the SEER BC dataset

No. Iteration	AdaBoost	GentleBoost	LogitBoost	Bagged trees	RUSBoost
10 Iteration	-	90.1	-	-	-
20 Iteration		95.3	-	-	-
30 Iteration	-	95.8	-	-	-
40 Iteration	-	95.9	-	-	-
50 Iteration	-	95.6	-	-	
60 Iteration	-	95.7	-	-	-
70 Iteration	-	95.7		-	-
80 Iteration		95.8	-	-	-
90 Iteration	-	95.8	-	-	-
100 Iteration	-	96	-	-	-
110 Iteration	-	96	-	-	-
120 Iteration	-	95.6	-		-

Table 9. Evaluation of the performance of the proposed framework applied to the SEER dataset

No. Iteration	Model	Evaluation Metric			
		Accuracy	Precision	Recall	F1-Score
10 Iteration	GentleBoost	90.1	96.4	93.8	95
20 Iteration	GentleBoost	95.3	96.9	93.8	95.3
30 Iteration	GentleBoost	95.8	97.4	94.2	95.8
40 Iteration	GentleBoost	95.9	97.6	94.2	95.9
50 Iteration	GentleBoost	95.6	97.4	93.8	95.6
60 Iteration	GentleBoost	95.7	97.4	94	95.7
70 Iteration	GentleBoost	95.7	97.4	94	95.7
80 Iteration	GentleBoost	95.8	97.4	94.2	95.8
90 Iteration	GentleBoost	95.8	97.4	94.2	95.8
100 Iteration	GentleBoost	96	98	94	96
110 Iteration	GentleBoost	96	97.4	94.2	95.7
120 Iteration	GentleBoost	95.6	97.3	94	95.6

4.3. Discussion of the results obtained by implementing the proposed framework on the BCCD. Table 10 presents the accuracy achieved in different numbers of iterations of the BCCD dataset. The results in Table 11 show the performance of several tree ensemble-based algorithms applied to the BCCD dataset for different numbers of iterations. Among all the algorithms, the Bagged trees algorithm achieved the highest performance in the case of 60 iterations, with an accuracy of 94.7%, a precision of 90%, a recall of 100%, and an F1-score of 94.7%. The results suggest that the Gentle-Boost algorithm is generally effective in classifying the BCCD dataset, achieving the highest performance in six of the 12 cases. However, the performance of the Gentle-Boost algorithm is not consistent across different numbers of iterations. For example, the algorithm achieved high performance in cases with 10, 20, 50, and 100 iterations, but its performance decreased in cases with 70, 80, and 120 iterations. Other tree ensemble-based algorithms, such as AdaBoost, LogitBoost, and RUSBoost, also achieved high performance in some cases; however, their performance was generally less consistent than that of Gentle-Boost. For example, AdaBoost achieved the highest performance in the cases of 40 and 90 iterations, but its performance was not as good in other cases. Similarly, LogitBoost and RUSBoost achieved the highest performance in the cases of 30 and 110 iterations, respectively; however, their performance dropped off in other cases. Overall, the results suggest that the bag algorithm is

effective for classifying the BCCD dataset. However, compared to the results obtained for the SEER BC dataset and the WDBC dataset, the performance of the tree ensemble-based algorithms for the BCCD dataset was generally lower.

Table 10. The accuracy achieved in different numbers of iterations of the BCCD dataset

No. Iteration	AdaBoost	GentleBoost	LogitBoost	Bag	RUSBoost
10 Iteration	-	78.9	-	-	-
20 Iteration		78.9	-	-	-
30 Iteration	-		84.2	-	-
40 Iteration	89.5		-	-	-
50 Iteration	-	68.4	-	-	
60 Iteration	-		-	94.7	-
70 Iteration	-	84.2		-	-
80 Iteration		84.2	-	-	-
90 Iteration	78.9		-	-	-
100 Iteration	-	68.4	-	-	-
110 Iteration	-		-	-	84.2
120 Iteration	84.2	-	-		-

Table 11. Evaluation of the performance of the proposed framework applied to BCCD

No. Iteration	Model	Evaluation Metrix			
		Accuracy	Precision	Recall	F1-Score
10 Iteration	GentleBoost	78.9	70	88.9	78.3
20 Iteration	GentleBoost	78.9	70	88.9	78.3
30 Iteration	LogitBoost	84.2	70	100	82.4
40 Iteration	AdaBoost	89.5	90	88.9	89.4
50 Iteration	GentleBoost	68.4	70	66.7	68.3
60 Iteration	Bag	94.7	90	100	94.7
70 Iteration	GentleBoost	84.2	90	77.8	83.5
80 Iteration	GentleBoost	84.2	90	77.8	83.5
90 Iteration	AdaBoost	78.9	70	88.9	78.3
100 Iteration	GentleBoost	68.4	70	66.7	68.3
110 Iteration	RUSBoost	84.2	70	100	82.4
120 Iteration	GentleBoost	84.2	90	77.8	83.5

5. Comparison of the results. This section presents a comparative analysis of the performance of multiple machine learning models for predicting BC using publicly available datasets such as WDBC, BCCD, and SEER BC. We evaluate the performance of both state-of-the-art models and the proposed framework. The performance of each model is assessed based on accuracy, precision, recall, and F1-score, and the best-performing model for BC prediction is identified. Additionally, we compare the performance of the proposed framework to the results reported in the literature for BC prediction.

5.1. Comparative Analysis of the Performance of Various Machine Learning Models in Predicting Breast Cancer. Table 12 showcases the results obtained from several machine learning models that were applied to three distinct datasets: WDBC, SEER, and BCCD, with a training and testing ratio of (80:20), (80:20), and (85:15), respectively. The experimental setup for these datasets is identical to the one mentioned in Section 3.1. The performance of the machine learning models was evaluated using metrics such as accuracy, precision, recall, and F1-Score. The metrics used to evaluate the performance of these models were accuracy, precision, recall, and F1-Score.

The best-performing model across all datasets was the proposed model, with perfect scores on the WDBC dataset and impressive results on the SEER and BCCD datasets. The proposed model's F1-Score, a measure that balances precision and recall, is particularly high, indicating strong performance in both identifying positive cases and limiting false positives.

The Cubic SVM and the Narrow, Wide, and Bilayered Neural Networks also achieved perfect scores on the WDBC dataset. However, their performance on the SEER and BCCD datasets is not as strong as that of the proposed model.

The Fine, Medium, and Coarse Trees, as well as the Linear SVM, showed consistent performance across all datasets; however, their scores were generally lower than those of the aforementioned models. The fine trees performed slightly better than the Medium and Coarse Trees, indicating that a more complex decision boundary might be beneficial for these datasets.

The Gaussian SVMs and KNN models exhibited varied performance. For instance, the Fine Gaussian SVM had high recall but lower precision, indicating a higher rate of false positives. The Course KNN, on the other hand, had high precision but low recall on the BCCD dataset, indicating a higher rate of false negatives.

The Neural Networks showed strong performance, particularly the Wide Neural Network and the Bilayered Neural Network. These models

achieved perfect scores on the WDBC dataset, and performed well on the SEER and BCCD datasets.

Table 12. The performance of various ML models

ML Model Name	Dataset	Accuracy	Precision	Recall	F1-Score
Fine Tress	WDBC	94.6	92.5	96.6	94.5
	SEER	91.9	94	89.8	91.9
	BCCD	84.2	70	100	82.4
Medium Tree	WDBC	94.6	92.5	96.6	94.5
	SEER	88	90.3	85.8	88
	BCCD	84.2	70	100	82.3
Coarse Tree	WDBC	92	86.8	96.6	91.4
	SEER	82.7	96.7	68.6	80.3
	BCCD	87.9	70	88.9	78.3
Linear SVM	WDBC	97.3	100	94.9	97.4
	SEER	80.1	83.2	77	80
	BCCD	84.2	100	66.7	80
Quadratic SVM	WDBC	99.1	100	98.3	99.1
	SEER	86	92.3	79.7	85.5
	BCCD	78.9	80	77.8	78.9
Cubic SVM	WDBC	100	100	100	100
	SEER	89.2	92.5	85.9	89.1
	BCCD	73.7	80	66.7	72.7
Fine Gaussian SVM	WDBC	92	83	100	90.7
	SEER	90.9	86.3	95.4	90.6
	BCCD	63.2	40	88.9	55.2
Medium Gaussian SVM	WDBC	99.1	98	97.3	97.6
	SEER	87.7	92.3	83	87.4
	BCCD	84.2	80	88.9	84.2
Coarse Gaussian SVM	WDBC	97.3	100	94.9	97.4
	SEER	79.7	82.7	76.6	79.5
	BCCD	68.4	90	44.4	59.5
Fine KNN	WDBC	96.4	92.5	100	96.1
	SEER	94	90.9	97.1	93.9
	BCCD	78.9	80	77.8	78.9
Medium KNN	WDBC	96.4	94.3	98.3	96.3
	SEER	85.9	88	83.8	85.8
	BCCD	78.9	90	66.7	76.6

Continuation of Table 12

ML Model Name	Dataset	Accuracy	Precision	Recall	F1-Score
Coarse KNN	WDBC	95.5	96.2	94.9	95.5
	SEER	78.8	86.3	71.4	78.1
	BCCD	57.9	100	11.1	19.9
Cosine KNN	WDBC	95.5	98.1	93.2	95.6
	SEER	84.3	87	81.6	84.2
	BCCD	73.3	90	55.6	68.7
Cubic KNN	WDBC	97.3	96.2	98.3	97.2
	SEER	84.2	84.1	84.3	84.2
	BCCD	84.2	90	77.8	83.5
Weighted KNN	WDBC	98.2	98.1	98.3	98.2
	SEER	91.9	89.1	94.7	91.8
	BCCD	78.9	90	66.7	76.6
Narrow Neural Network	WDBC	100	100	100	100
	SEER	87.3	90.3	84.3	87.2
	BCCD	68.4	80	55.6	65.6
Medium Neural Network	WDBC	99.1	98.1	100	99.0
	SEER	88.1	87.8	88.5	88.1
	BCCD	73.3	80	66.7	72.7
Wide Neural Network	WDBC	100	100	100	100
	SEER	91.8	90.5	93.1	91.8
	BCCD	78.9	90	66.7	76.6
Bilayered Neural Network	WDBC	100	100	100	100
	SEER	87.3	87	87.6	87.3
	BCCD	78.9	80	77.8	78.9
Trilayered Neural Network	WDBC	100	100	100	100
	SEER	88.8	89.8	87.8	88.8
	BCCD	73.7	80	66.7	72.7
The proposed	WDBC	100	100	100	100
	SEER	95.9	97.6	94.2	95.9
	BCCD	94.7	90	100	94.7

5.2. Comparison with previous studies. According to Table 13, hyperparameter tuning plays a crucial role in improving the performance of ML models. The proposed framework utilizes the power of Bayesian optimization and Tree ensemble-based models in an iterative process to achieve the best possible results. Table 13 indicates that the proposed

framework outperforms the results reported in the literature for the three commonly used datasets.

Table 13. Comparison with previous studies

Ref.	Year	Dataset	Methods/Techniques	Accuracy
[10]	2019	WDBC	WQPSO with smooth SVM	98.42
[15]	2019	SEER BC	Gradient Boosting with Genetic Algorithm	75.03
[13]	2020	WDBC	Optimized FSTBSVM with Jaya optimization techniques	94.36
[16]	2020	SEER BC	Improved Random Forest - based rule extraction	80.5
[19]	2020	BCCD	GA and Gradient Boosting Classifier	79
[14]	2021	WDBC	SVM, LR, KNN, DT, Naive Bayes, and RF	SVM and RF = 96.5
[9]	2022	WDBC	Optimized SVM with Bayesian hyperparameter optimization	99.3
[18]	2022	SEER BC	RF	94.6
[9]	2022	DCCD	Optimized SVM with Bayesian hyperparameter optimization	76.9
The proposed	2023	WDBC	Tree ensemble-based models with iterative tuning of Bayesian optimization	100
		SEER		95.9
		BCCD		94.7

6. Conclusion. This paper presents a method for the iterative tuning of tree-ensemble-based model parameters using Bayesian hyperparameter tuning for BC prediction. The proposed method achieved perfect scores on the WDBC dataset and impressive results on the SEER and BCCD datasets. The results show that the proposed method can significantly improve the performance of tree ensemble-based models for BC prediction. By utilizing Bayesian hyperparameter tuning, we were able to identify the optimal hyperparameter values for the models, resulting in a higher accuracy. The optimized tree ensemble-based models' high F1-Score indicates their effectiveness in identifying positive cases and limiting false positives, making them a robust and reliable option for generalization. Compared with various state-of-the-art models, the proposed method is more efficient. The outcomes of this study have important implications for medical professionals, as the early detection of BC can significantly increase the chances of survival. By utilizing ML models, such as tree ensemble-based models, and optimizing their hyperparameters using Bayesian hyperparameter tuning, medical professionals can improve their ability to

detect BC in its early stages, leading to better patient outcomes. Overall, this study provides a valuable contribution to the field of BC prediction using ML, and its proposed method can be extended to other domains where tree ensemble-based models are used.

References

1. Rabiei R., Ayyoubzadeh S.M., Sohrabei S., Esmaceli M., Atashi A. Prediction of breast cancer using machine learning approaches. *Journal of Biomedical Physics and Engineering*. 2022. vol. 12. no. 3. pp. 297–308. DOI: 10.31661/jbpe.v0i0.2109-1403.
2. Visvanathan K., Fabian C.J., Bantug E., Brewster A.M., Davidson N.E., DeCensi A., et al. Use of endocrine therapy for breast cancer risk reduction: ASCO clinical practice guideline update. *Journal of clinical oncology*. 2019. vol. 37. no. 33. pp. 3152–3165.
3. Thirthagiri E., Lee S.Y., Kang P., Lee D.S., Toh G.T., Selamat S., Yoon S.Y., Mohd Taib N.A., Nhong M.K., Yip C.H., Teo S.H. Evaluation of BRCA1 and BRCA2 mutations and risk-prediction models in a typical Asian country (Malaysia) with a relatively low incidence of breast cancer. *Breast Cancer Research*. 2008. vol. 10. no. 4. pp. 1–12. DOI: 10.1186/bcr2118.
4. Monirujjaman Khan M., Islam S., Sarkar S., Ayaz F.I., Kabir M.M., Tazin T., Albraikan A.A., Almalki F.A. Machine learning based comparative analysis for breast cancer prediction. *Journal of Healthcare Engineering*. 2022. vol. 2022. DOI: 10.1155/2022/4365855.
5. Sharma D., Kumar R., Jain A. Breast Cancer Patient Classification from Risk Factor Analysis Using Machine Learning Classifiers. *Emergent Converging Technologies and Biomedical Systems: Select Proceedings of ETBS 2021*. 2022. pp. 491–504.
6. Ali S., Majid A., Javed S.G., Sattar M. Can-CSC-GBE: Developing Cost-sensitive Classifier with Gentleboost Ensemble for breast cancer classification using protein amino acids and imbalanced data. *Computers in biology and medicine*. 2016. vol. 73. pp. 38–46.
7. Gao L., Ding Y. Disease prediction via Bayesian hyperparameter optimization and ensemble learning. *BMC research notes*. 2020. vol. 13. pp. 1–6.
8. Sharma S.K., Vijayakumar K., Kadam V.J., Williamson S. Breast cancer prediction from microRNA profiling using random subspace ensemble of LDA classifiers via Bayesian optimization. *Multimedia Tools and Applications*. 2022. vol. 81. no. 29. pp. 41785–41805.
9. Rasool A., Bunterngchit C., Tiejian L., Islam M.R., Qu Q., Jiang Q. Improved machine learning-based predictive models for breast cancer diagnosis. *International journal of environmental research and public health*. 2022. vol. 19(6). no. 3211. DOI: 10.3390/ijerph19063211.
10. Latchoumi T.P., Ezhilarasi T.P., Balamurugan K. Bio-inspired weighed quantum particle swarm optimization and smooth support vector machine ensembles for identification of abnormalities in medical data. *SN Applied Sciences*. 2019. vol. 1(10). no. 1137. DOI: 10.1007/s42452-019-1179-8.
11. Lahoura V., Singh H., Aggarwal A., Sharma B., Mohammed M.A., Damasevicius R., Kadry F., Cengiz K. Cloud computing-based framework for breast cancer diagnosis using extreme learning machine. *Diagnostics*. 2021. vol. 11(2). no. 241. DOI: 10.3390/diagnostics11020241.
12. Showrov M.I.H., Islam M.T., Hossain M.D., Ahmed M.S. Performance comparison of three classifiers for the classification of breast cancer dataset. in *4th International*

- conference on electrical information and communication technology (EICT). 2019. pp. 1–5.
13. Sheth P.D., Patil S.T., Dhore M.L. Evolutionary computing for clinical dataset classification using a novel feature selection algorithm. *Journal of King Saud University-Computer and Information Sciences*. 2022. vol. 34. pp. 5075–5082.
 14. Ara S., Das A., Dey A. Malignant and benign breast cancer classification using machine learning algorithms. in *2021 International Conference on Artificial Intelligence (ICAI)*. 2021. pp. 97–101.
 15. Lu H., Wang H., Yoon S.W. A dynamic gradient boosting machine using genetic optimizer for practical breast cancer prognosis. *Expert Systems with Applications*. 2019. vol. 116. pp. 340–350.
 16. Wang S., Wang Y., Wang D., Yin Y., Wang Y., Jin Y. An improved random forest-based rule extraction method for breast cancer diagnosis. *Applied Soft Computing*. 2020. vol. 86. no. 105941. DOI: 10.1016/j.asoc.2019.105941.
 17. Ozkan G.Y., Gunduz S.Y. Comparison of Classification Algorithms for Survival of Breast Cancer Patients. *Innovations in Intelligent Systems and Applications Conference (ASYU)*. 2020. pp. 1–4.
 18. Haque M.N., Tazin T., Khan M.M., Faisal S., Ibraheem S.M., Algethami H., Almalki F.A. Predicting characteristics associated with breast cancer survival using multiple machine learning approaches. *Computational and Mathematical Methods in Medicine*. 2022. vol. 2022. pp. 1–12. DOI: 10.1155/2022/1249692.
 19. Mishra A.K., Roy P., Bandyopadhyay S. Genetic algorithm based selection of appropriate biomarkers for improved breast cancer prediction. *Intelligent Systems and Applications: Proceedings of the Intelligent Systems Conference (IntelliSys)*. 2020. vol. 2. pp. 724–732.
 20. Mishra A.K., Roy P., Bandyopadhyay S. Binary particle swarm optimization based feature selection (bpso-fs) for improving breast cancer prediction. *Proceedings of International Conference on Artificial Intelligence and Applications: ICAIA 2020*. 2021. pp. 373–384.
 21. Breiman L. Bagging predictors. *Machine learning*. 1996. vol. 24. pp. 123–140.
 22. Harrou F., Saidi A., Sun Y. Wind power prediction using bootstrap aggregating trees approach to enabling sustainable wind power integration in a smart grid. *Energy Conversion and Management*. 2019. vol. 201. no. 112077. DOI: 10.1016/j.enconman.2019.112077.
 23. Buhlmann P., Yu B. Analyzing bagging. *The annals of Statistics*. 2002. vol. 30. no. 4. pp. 927–961.
 24. Liu C., Zhao Z., Gu X., Sun L., Chen G., Zhang H., Jiang Y., Zhang Y., Cui X., Liu C. Establishment and verification of a bagged-trees-based model for prediction of sentinel lymph node metastasis for early breast cancer patients. *Frontiers in Oncology*. 2019. vol. 9. no. 282. DOI: 10.3389/fonc.2019.00282.
 25. Deepa R., Gnanadesigan R., Ranjith D., Nithishkumar K., Dinesh A., Moorthy C. Performance Analysis of the Classification of Breast Cancer. *Third International Conference on Inventive Research in Computing Applications (ICIRCA)*. 2021. pp. 1–6.
 26. Dawngliani M., Chandrasekaran N., Lalmuanawma S., Thangkhanhau H. Prediction of breast cancer recurrence using ensemble machine learning classifiers. *Security with Intelligent Computing and Big-Data Services 2019: Proceedings of the 3rd International Conference on Security with Intelligent Computing and Big-data Services (SICBS)*. 2020. pp. 232–244.
 27. Assegie T.A., Tulasi R.L., Kumar N.K. Breast cancer prediction model with decision tree and adaptive boosting. *IAES International Journal of Artificial Intelligence*. 2021. vol. 10(1). no. 184.

28. Okagbue H.I., Adamu P.I., Oguntunde P.E., Obasi E.C., Odetunmbi O.A. Machine learning prediction of breast cancer survival using age, sex, length of stay, mode of diagnosis and location of cancer. *Health and Technology*. 2021. vol. 11. pp. 887–893.
29. Friedman J., Hastie T., Tibshirani R. Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors). *The annals of statistics*. 2000. vol. 28. no. 2. pp. 337–407.
30. Wu J., Gan M., Jiang R. A genetic algorithm for optimizing subnetwork markers for the study of breast cancer metastasis. *Seventh International Conference on Natural Computation*. 2011. pp. 1578–1582.
31. Seiffert C., Khoshgoftaar T.M., Van Hulse J., Napolitano A. RUSBoost: A hybrid approach to alleviating class imbalance. *IEEE transactions on systems, man, and cybernetics-part A: systems and humans*. 2009. vol. 40. pp. 185–197.
32. Tian J.-X., Zhang J. Breast cancer diagnosis using feature extraction and boosted C5.0 decision tree algorithm with penalty factor. *Math Biosci Eng*. 2022. vol. 19. no. 3. pp. 2193–2205.
33. Jiang X., Xu C. Deep learning and machine learning with grid search to predict later occurrence of breast Cancer metastasis using clinical data. *Journal of clinical medicine*. 2022. vol. 11(19). no. 5772.
34. Deshwal V., Sharma M. Breast cancer detection using SVM classifier with grid search technique. *International Journal of Computer Applications*. 2019. vol. 975. no. 8887.
35. Buttan Y., Chaudhary A., Saxena K. An improved model for breast cancer classification using random forest with grid search method. *Proceedings of Second International Conference on Smart Energy and Communication: ICSEC 2020*. 2021. pp. 407–415.
36. Assegie T.A. An optimized K-Nearest Neighbor based breast cancer detection. *Journal of Robotics and Control (JRC)*. 2021. vol. 2. no. 3. pp. 115–118.
37. Mate Y., Somai N. Hybrid feature selection and Bayesian optimization with machine learning for breast cancer prediction. *7th International Conference on Advanced Computing and Communication Systems (ICACCS)*. 2021. pp. 612–619.
38. Ceylan Z. Diagnosis of breast cancer using improved machine learning algorithms based on bayesian optimization. *International Journal of Intelligent Systems and Applications in Engineering*. 2020. vol. 8. no. 3. pp. 121–130.
39. kaggle Repository. Breast Cancer Wisconsin Diagnostic Dataset. Available at: <https://www.kaggle.com/code/karan1210/breast-cancer/data>. (accessed 07.06.2022).
40. kaggle Repository. Breast Cancer Coimbra Dataset. Available at: <https://www.kaggle.com/datasets/yasserhessein/breast-cancer-coimbra-data-set>. (accessed 07.06.2022).
41. Surveillance, Epidemiology, and End Results (SEER) program. SEER breast cancer data. Available at: <https://ieee-dataport.org/open-access/seer-breast-cancer-data>. (accessed 07.06.2022).

Alsabry Ayman — Graduate student, Department of computer science, Sana'a University. Research interests: computer science, artificial intelligence, machine learning. The number of publications — 7. aymanalsabri@su.edu.ye; Sana'a University St., Sana'a, Yemen; office phone: +967(774)265-262.

Algabri Malek — Ph.D., Associate Professor, Head of the department, Department of computer science, faculty of computing and information technology, Sana'a University. Research interests: computer science, MANETs, MPLS, artificial intelligence, machine learning. The number of publications — 17. malekye@su.edu.ye; Sana'a University St., Sana'a, Yemen; office phone: +967(777)662-909.

А. АЛСАБРИ, М. АЛЬГАБРИ

ИТЕРАТИВНАЯ НАСТРОЙКА ПАРАМЕТРОВ МОДЕЛЕЙ НА ОСНОВЕ ДРЕВОВИДНЫХ АНСАМБЛЕЙ С ИСПОЛЬЗОВАНИЕМ БАЙЕСОВСКОЙ ОПТИМИЗАЦИИ ДЛЯ ПРОГНОЗИРОВАНИЯ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ

Алсабри А., Альгабри М. Итеративная настройка параметров моделей на основе древовидных ансамблей с использованием байесовской оптимизации для прогнозирования рака молочной железы.

Аннотация. Представлен метод итеративной настройки параметров моделей на основе ансамблей деревьев с использованием настройки байесовских гиперпараметров для прогнозирования состояний на примере рака молочной железы. Предлагаемый метод использует три различных набора данных, в том числе набор данных по диагностическому раку молочной железы Висконсина (WDBC), набор данных по надзору, эпидемиологии и конечным результатам (SEER) по раку молочной железы и набор данных по раку молочной железы в Коимбре (BCCD), а также реализует набор данных на основе древовидных ансамблей. Модели, в частности AdaBoost, Gentle-Boost, LogitBoost, Bag и RUSBoost, для прогнозирования рака молочной железы. Байесовская оптимизация использовалась для итеративной настройки гиперпараметров моделей, а производительность моделей оценивалась с использованием нескольких показателей, включая точность, прецизионность, полноту и оценку f1. Наши результаты показывают, что предложенный метод значительно повышает производительность моделей на основе ансамблей деревьев, что приводит к более высокой точности, прецизионности, полноте и оценке f1. По сравнению с другими современными моделями предлагаемый метод более эффективен. Он достиг 100% идеальных результатов по точности, прецизионности, полноте и оценке F1 в наборе данных WDBC. В наборе данных SEER BC точность метода составила 95,9%, прецизионность 97,6%, полнота 94,2% и оценка F1 95,9%. Для набора данных BCCD метод достиг точности 94,7%, прецизионности 90%, полноты 100% и оценки F1 94,7%. Результаты этого исследования имеют важное значение для медицинских работников, поскольку раннее выявление рака молочной железы может значительно повысить шансы на выживание. В целом, это исследование вносит ценный вклад в область прогнозирования рака молочной железы с использованием машинного обучения.

Ключевые слова: итеративная настройка, модели на основе древовидных ансамблей, байесовская оптимизация, рак молочной железы, машинное обучение.

Литература

1. Rabiei R., Ayyoubzadeh S.M., Sohrabei S., Esmaceli M., Atashi A. Prediction of breast cancer using machine learning approaches. Journal of Biomedical Physics and Engineering. 2022. vol. 12. no. 3. pp. 297–308. DOI: 10.31661/jbpe.v0i0.2109-1403.
2. Visvanathan K., Fabian C.J., Bantug E., Brewster A.M., Davidson N.E., DeCensi A., et al. Use of endocrine therapy for breast cancer risk reduction: ASCO clinical practice guideline update. Journal of clinical oncology. 2019. vol. 37. no. 33. pp. 3152–3165.
3. Thirthagiri E., Lee S.Y., Kang P., Lee D.S., Toh G.T., Selamat S., Yoon S.Y., Mohd Taib N.A., Nhong M.K., Yip C.H., Teo S.H. Evaluation of BRCA1 and BRCA2 mutations and risk-prediction models in a typical Asian country (Malaysia) with a

- relatively low incidence of breast cancer. *Breast Cancer Research*. 2008. vol. 10. no. 4. pp. 1–12. DOI: 10.1186/bcr2118.
4. Monirujjaman Khan M., Islam S., Sarkar S., Ayaz F.I., Kabir M.M., Tazin T., Albraikan A.A., Almalki F.A. Machine learning based comparative analysis for breast cancer prediction. *Journal of Healthcare Engineering*. 2022. vol. 2022. DOI: 10.1155/2022/4365855.
 5. Sharma D., Kumar R., Jain A. Breast Cancer Patient Classification from Risk Factor Analysis Using Machine Learning Classifiers. *Emergent Converging Technologies and Biomedical Systems: Select Proceedings of ETBS 2021*. 2022. pp. 491–504.
 6. Ali S., Majid A., Javed S.G., Sattar M. Can-CSC-GBE: Developing Cost-sensitive Classifier with Gentleboost Ensemble for breast cancer classification using protein amino acids and imbalanced data. *Computers in biology and medicine*. 2016. vol. 73. pp. 38–46.
 7. Gao L., Ding Y. Disease prediction via Bayesian hyperparameter optimization and ensemble learning. *BMC research notes*. 2020. vol. 13. pp. 1–6.
 8. Sharma S.K., Vijayakumar K., Kadam V.J., Williamson S. Breast cancer prediction from microRNA profiling using random subspace ensemble of LDA classifiers via Bayesian optimization. *Multimedia Tools and Applications*. 2022. vol. 81. no. 29. pp. 41785–41805.
 9. Rasool A., Bunterngchit C., Tiejian L., Islam M.R., Qu Q., Jiang Q. Improved machine learning-based predictive models for breast cancer diagnosis. *International journal of environmental research and public health*. 2022. vol. 19(6). no. 3211. DOI: 10.3390/ijerph19063211.
 10. Latchoumi T.P., Ezhilarasi T.P., Balamurugan K. Bio-inspired weighed quantum particle swarm optimization and smooth support vector machine ensembles for identification of abnormalities in medical data. *SN Applied Sciences*. 2019. vol. 1(10). no. 1137. DOI: 10.1007/s42452-019-1179-8.
 11. Lahoura V., Singh H., Aggarwal A., Sharma B., Mohammed M.A., Damasevicius R., Kadry F., Cengiz K. Cloud computing-based framework for breast cancer diagnosis using extreme learning machine. *Diagnostics*. 2021. vol. 11(2). no. 241. DOI: 10.3390/diagnostics11020241.
 12. Showrov M.I.H., Islam M.T., Hossain M.D., Ahmed M.S. Performance comparison of three classifiers for the classification of breast cancer dataset. in *4th International conference on electrical information and communication technology (EICT)*. 2019. pp. 1–5.
 13. Sheth P.D., Patil S.T., Dhore M.L. Evolutionary computing for clinical dataset classification using a novel feature selection algorithm. *Journal of King Saud University-Computer and Information Sciences*. 2022. vol. 34. pp. 5075–5082.
 14. Ara S., Das A., Dey A. Malignant and benign breast cancer classification using machine learning algorithms. in *2021 International Conference on Artificial Intelligence (ICAI)*. 2021. pp. 97–101.
 15. Lu H., Wang H., Yoon S.W. A dynamic gradient boosting machine using genetic optimizer for practical breast cancer prognosis. *Expert Systems with Applications*. 2019. vol. 116. pp. 340–350.
 16. Wang S., Wang Y., Wang D., Yin Y., Wang Y., Jin Y. An improved random forest-based rule extraction method for breast cancer diagnosis. *Applied Soft Computing*. 2020. vol. 86. no. 105941. DOI: 10.1016/j.asoc.2019.105941.
 17. Ozkan G.Y., Gunduz S.Y. Comparison of Classification Algorithms for Survival of Breast Cancer Patients. *Innovations in Intelligent Systems and Applications Conference (ASYU)*. 2020. pp. 1–4.
 18. Haque M.N., Tazin T., Khan M.M., Faisal S., Ibraheem S.M., Algethami H., Almalki F.A. Predicting characteristics associated with breast cancer survival using multiple

- machine learning approaches. *Computational and Mathematical Methods in Medicine*. 2022. vol. 2022. pp. 1–12. DOI: 10.1155/2022/1249692.
19. Mishra A.K., Roy P., Bandyopadhyay S. Genetic algorithm based selection of appropriate biomarkers for improved breast cancer prediction. *Intelligent Systems and Applications: Proceedings of the Intelligent Systems Conference (IntelliSys)*. 2020. vol. 2. pp. 724–732.
 20. Mishra A.K., Roy P., Bandyopadhyay S. Binary particle swarm optimization based feature selection (bpso-fs) for improving breast cancer prediction. *Proceedings of International Conference on Artificial Intelligence and Applications: ICAIA 2020*. 2021. pp. 373–384.
 21. Breiman L. Bagging predictors. *Machine learning*. 1996. vol. 24. pp. 123–140.
 22. Harrou F., Saïdi A., Sun Y. Wind power prediction using bootstrap aggregating trees approach to enabling sustainable wind power integration in a smart grid. *Energy Conversion and Management*. 2019. vol. 201. no. 112077. DOI: 10.1016/j.enconman.2019.112077.
 23. Buhlmann P., Yu B. Analyzing bagging. *The annals of Statistics*. 2002. vol. 30. no. 4. pp. 927–961.
 24. Liu C., Zhao Z., Gu X., Sun L., Chen G., Zhang H., Jiang Y., Zhang Y., Cui X., Liu C. Establishment and verification of a bagged-trees-based model for prediction of sentinel lymph node metastasis for early breast cancer patients. *Frontiers in Oncology*. 2019. vol. 9. no. 282. DOI: 10.3389/fonc.2019.00282.
 25. Deepa R., Gnanadesigan R., Ranjith D., Nithishkumar K., Dinesh A., Moorthy C. Performance Analysis of the Classification of Breast Cancer. *Third International Conference on Inventive Research in Computing Applications (ICIRCA)*. 2021. pp. 1–6.
 26. Dawngliani M., Chandrasekaran N., Lalmuanawma S., Thangkhanhau H. Prediction of breast cancer recurrence using ensemble machine learning classifiers. *Security with Intelligent Computing and Big-Data Services 2019: Proceedings of the 3rd International Conference on Security with Intelligent Computing and Big-data Services (SICBS)*. 2020. pp. 232–244.
 27. Assegie T.A., Tulasi R.L., Kumar N.K. Breast cancer prediction model with decision tree and adaptive boosting. *IAES International Journal of Artificial Intelligence*. 2021. vol. 10(1). no. 184.
 28. Okagbue H.L., Adam P.I., Oguntunde P.E., Obasi E.C., Odetunmbi O.A. Machine learning prediction of breast cancer survival using age, sex, length of stay, mode of diagnosis and location of cancer. *Health and Technology*. 2021. vol. 11. pp. 887–893.
 29. Friedman J., Hastie T., Tibshirani R. Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors). *The annals of statistics*. 2000. vol. 28. no. 2. pp. 337–407.
 30. Wu J., Gan M., Jiang R. A genetic algorithm for optimizing subnetwork markers for the study of breast cancer metastasis. *Seventh International Conference on Natural Computation*. 2011. pp. 1578–1582.
 31. Seiffert C., Khoshgoftaar T.M., Van Hulse J., Napolitano A. RUSBoost: A hybrid approach to alleviating class imbalance. *IEEE transactions on systems, man, and cybernetics-part A: systems and humans*. 2009. vol. 40. pp. 185–197.
 32. Tian J.-X., Zhang J. Breast cancer diagnosis using feature extraction and boosted C5.0 decision tree algorithm with penalty factor. *Math Biosci Eng*. 2022. vol. 19. no. 3. pp. 2193–2205.
 33. Jiang X., Xu C. Deep learning and machine learning with grid search to predict later occurrence of breast Cancer metastasis using clinical data. *Journal of clinical medicine*. 2022. vol. 11(19). no. 5772.

34. Deshwal V., Sharma M. Breast cancer detection using SVM classifier with grid search technique. *International Journal of Computer Applications*. 2019. vol. 975. no. 8887.
35. Buttan Y., Chaudhary A., Saxena K. An improved model for breast cancer classification using random forest with grid search method. *Proceedings of Second International Conference on Smart Energy and Communication: ICSEC 2020*. 2021. pp. 407–415.
36. Assegie T.A. An optimized K-Nearest Neighbor based breast cancer detection. *Journal of Robotics and Control (JRC)*. 2021. vol. 2. no. 3. pp. 115–118.
37. Mate Y., Somai N. Hybrid feature selection and Bayesian optimization with machine learning for breast cancer prediction. *7th International Conference on Advanced Computing and Communication Systems (ICACCS)*. 2021. pp. 612–619.
38. Ceylan Z. Diagnosis of breast cancer using improved machine learning algorithms based on bayesian optimization. *International Journal of Intelligent Systems and Applications in Engineering*. 2020. vol. 8. no. 3. pp. 121–130.
39. kaggle Repository. Breast Cancer Wisconsin Diagnostic Dataset. Available at: <https://www.kaggle.com/code/karan1210/breast-cancer/data>. (accessed 07.06.2022).
40. kaggle Repository. Breast Cancer Coimbra Dataset. Available at: <https://www.kaggle.com/datasets/yasserhessein/breast-cancer-coimbra-data-set>. (accessed 07.06.2022).
41. Surveillance, Epidemiology, and End Results (SEER) program. SEER breast cancer data. Available at: <https://ieee-dataport.org/open-access/seer-breast-cancer-data>. (accessed 07.06.2022).

Алсабри Айман — аспирант, кафедра информатики, Университет Саны. Область научных интересов: информатика, искусственный интеллект, машинное обучение. Число научных публикаций — 7. aymanalsabri@su.edu.ye; Университетская улица Саны, Сана, Йемен; р.т.: +967(774)265-262.

Альгабри Малек — Ph.D., доцент, руководитель отдела, кафедра информатики, факультет вычислительной техники и информационных технологий, Университет Саны. Область научных интересов: информатика, MANETs, MPLS, искусственный интеллект, машинное обучение. Число научных публикаций — 17. malekye@su.edu.ye; Университетская улица Саны, Сана, Йемен; р.т.: +967(777)662-909.

Д.С. СОЛОВЬЕВ

**МЕТОД РАСЧЕТА КОЭФФИЦИЕНТОВ КОМПЕТЕНТНОСТИ
УЧАСТНИКОВ ГРУППОВОГО ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ
ВЫБОРА НАИЛУЧШЕЙ АЛЬТЕРНАТИВЫ ПРИ
МУЛЬТИВАРИАНТНОСТИ РЕЗУЛЬТАТА**

Соловьев Д.С. Метод расчета коэффициентов компетентности участников группового принятия решений для выбора наилучшей альтернативы при мультивариантности результата.

Аннотация. В работе рассматривается проблема получения наилучшей альтернативы с помощью методов принятия решений, основанных на опыте специалиста и математических расчетов. Для решения данной проблемы подходит групповое принятие решений, однако оно может привести к выбору нескольких наилучших альтернатив (мультивариантности результата). Учет компетентности позволит отдать приоритет решению более компетентных участников и устранить возникновение нескольких наилучших альтернатив в процессе группового принятия решений. Сформулирована задача определения коэффициентов компетентности для участников группового принятия решений, которые обеспечивают выбор наилучшей альтернативы при мультивариантности результата. Разработан метод решения поставленной задачи, который включает в себя дискретизацию диапазона изменения входных переменных и уточнение в нем значений коэффициентов компетентности участников группового принятия решений. Уточнение выполняется с использованием либо мажоритарного принципа, либо с помощью лица, принимающего решение. Последующее вычисление коэффициентов компетентности для участников группового принятия решений осуществляется при помощи локальной линейной интерполяции уточненного коэффициента компетентности в окружающих точках из дискретизированного диапазона. Использование предложенного метода решения поставленной задачи рассмотрено на примере группового принятия решений по основным разновидностям мажоритарного принципа для выбора варианта технологического процесса нанесения гальванического покрытия. В результатах показано, что предложенный метод расчета коэффициентов компетентности участников группового принятия решений через локальную линейную интерполяцию является наиболее эффективным для выбора наилучшей альтернативы при мультивариантности результата по мажоритарному принципу относительного большинства.

Ключевые слова: коэффициенты компетентности, групповое принятие решений, выбор лучшей альтернативы, мультивариантность результата.

1. Введение. Основной целью принятия решений является выбор наилучшей альтернативы, среди отличающихся вариантов [1, 2]. Для ее достижения необходимо сравнить различные альтернативы и выбрать ту, которая наилучшим образом соответствует поставленной цели. Мерами оценки соответствия рассматриваемых альтернатив поставленной цели являются показатели, по значениям которых оцениваются альтернативы и выбирается лучший вариант. Однако, как правило, у каждой альтернативы есть свои преимущества и недостатки, и выбор лучшего решения может быть сложным

процессом. Существуют различные методы принятия решений (МПР), разделенные на два класса. Методы в первом классе основываются на опыте и интуиции лица, принимающего решение (ЛПР) [3, 4]. В таком случае не гарантируется получение неправильной или единственной альтернативы из-за субъективности ЛПР. Методы во втором классе используют математические подходы [5, 6]. Поскольку алгоритмы расчета в данных МПР отличаются, то результат выбора наилучшей альтернативы также может отличаться. Сравнение эффективности выбора наилучшей альтернативы для группового голосования с помощью математических МПР рассматривается, например, в исследованиях [7 – 9]. Выбор в качестве участников группового принятия решений математических методов обуславливается скоростью (экономия времени), прозрачностью (известен алгоритм расчета) и простотой («физическое» отсутствие участников) реализации процедуры определения наилучшей альтернативы. Подразумевается, что наилучшие альтернативы, которые выбраны по мажоритарному принципу (большинством МПР), в большей степени учитывают предпочтения всех участников голосования и являются объективными и единственно «справедливыми» для группы в целом, нежели те альтернативы, которые выбраны меньшинством МПР [10]. Однако исследованиям в данном направлении присущ общий недостаток – отсутствие обоснований по выбору единственного решения в случае мультивариантности результата (нескольких наилучших альтернатив). Одной из причин возникновения нескольких наилучших альтернатив является недостаточная оценка компетентности участников группы, определяющей их способность вносить значимый вклад в процесс принятия решений [11]. В случае использования в качестве участников голосования математических МПР под их компетентностью понимается степень правильности интерпретации и использования информации методом для выбора наилучшей альтернативы. Учет компетентности позволит отдать приоритет решению более компетентных участников и устранить возникновение нескольких наилучших альтернатив в процессе группового принятия решений. Таким образом, разработка метода расчета коэффициентов компетентности позволит определить вклад каждого участника в принятые решения и произвести выбор наилучшей альтернативы при мультивариантности результата с учетом компетентности членов группы, усиливающий уровень уверенности в его правильности.

Целью работы является создание метода расчета коэффициентов компетентности участников группового принятия

решений для выбора наилучшей альтернативы при мультивариантности результата.

2. Постановка задачи. Пусть задано множество возможных вариантов (альтернатив), используемых в задаче принятия решений:

$$\mathbf{A} = \{A_1, \dots, A_m, \dots, A_M\}, \quad (1)$$

для оценки которых применяется множество характеристик (показателей):

$$\mathbf{K} = \{K_1, \dots, K_n, \dots, K_N\}, \quad (2)$$

где \mathbf{A} , \mathbf{K} – множества альтернатив и показателей; A_m – m -я альтернатива; K_n – n -й показатель; M , N – количество альтернатив и показателей.

Для кортежа заданных значений входных переменных:

$$\mathbf{X}^{set} = \left(\langle X_1:Val_1^{set} \rangle, \dots, \langle X_i:Val_i^{set} \rangle, \dots, \langle X_I:Val_I^{set} \rangle \right), \quad (3)$$

определена таблица (матрица решений) со значениями альтернатив (1) по показателям (2):

$$\mathbf{S}^{set} = \begin{pmatrix} S_{1,1}^{set} & S_{1,2}^{set} & \dots & S_{1,N}^{set} \\ S_{2,1}^{set} & S_{2,2}^{set} & \dots & S_{2,N}^{set} \\ \dots & \dots & \dots & \dots \\ S_{M,1}^{set} & S_{M,2}^{set} & \dots & S_{M,N}^{set} \end{pmatrix}, \quad (4)$$

с относительной важностью каждого показателя (весовыми коэффициентами значимости показателей):

$$\mathbf{W}^{set} = \left(W_1^{set}, \dots, W_n^{set}, \dots, W_N^{set} \right), \quad (5)$$

для достижения цели (выбор наилучшей альтернативы) посредством группового принятия решений при помощи кортежа методов:

$$\mathbf{F} = \left(\langle nF_1:F_1(\mathbf{S}, \mathbf{W}) \rangle, \dots, \langle nF_l:F_l(\mathbf{S}, \mathbf{W}) \rangle, \dots, \langle nF_L:F_L(\mathbf{S}, \mathbf{W}) \rangle \right), \quad (6)$$

где \mathbf{X}^{set} – кортеж заданных значений входных переменных; X_i – наименование i -й переменной; Val_i^{set} – значение i -й переменной; I – количество переменных; \mathbf{S}^{set} – матрица решений; $S_{m,n}^{set}$ – значение m -й альтернативы по n -му показателю; \mathbf{W}^{set} – вектор весовых коэффициентов; W_n – весовой коэффициент значимости n -го показателя; \mathbf{F} – кортеж МПР; nF_l – наименование l -го МПР; F_l – функция, реализующая l -й МПР; L – количество МПР.

Требуется для заданных значений входных переменных (3) по матрице решений (4) и весовым коэффициентам (5) показателей (2) определить для участников группового принятия решений (6) способность правильно понимать и использовать информацию для достижения цели (коэффициенты компетентности):

$$\mathbf{r}^{set} = (r_1^{set}, \dots, r_l^{set}, \dots, r_L^{set}), \quad (7)$$

которые с использованием мажоритарного принципа обеспечивают выбор наилучшей альтернативы из (1) при мультивариантности результата, то есть:

$$\dim \tilde{\mathbf{A}}^{set} = 1, \quad (8)$$

где \mathbf{r}^{set} – вектор коэффициентов компетентности МПР; r_l^{set} – коэффициент компетентности l -го МПР; $\tilde{\mathbf{A}}^{set}$ – множество наилучших альтернатив; \dim – размерность множества наилучших альтернатив.

3. Метод решения поставленной задачи. Для кортежа (3) с помощью декартова произведения из дискретных значений внутри допустимого диапазона изменения входных переменных формируется

совокупность из $\prod_{i=1}^I J_i$ кортежей:

$$\mathbf{X}^{j_1, \dots, j_i, \dots, j_I} = (\langle X_1:Val_{1,j_1} \rangle, \dots, \langle X_i:Val_{i,j_i} \rangle, \dots, \langle X_I:Val_{I,j_I} \rangle), (j_i = 1, 2, \dots, J_i), \quad (9)$$

где J_i – количество дискретных значений i -й переменной.

Каждому кортежу (9) определяется матрица решений:

$$\mathbf{S}^{j_1, \dots, j_i, \dots, j_I} = \begin{pmatrix} S_{1,1}^{j_1, \dots, j_i, \dots, j_I} & S_{1,2}^{j_1, \dots, j_i, \dots, j_I} & \dots & S_{1,N}^{j_1, \dots, j_i, \dots, j_I} \\ S_{2,1}^{j_1, \dots, j_i, \dots, j_I} & S_{2,2}^{j_1, \dots, j_i, \dots, j_I} & \dots & S_{2,N}^{j_1, \dots, j_i, \dots, j_I} \\ \dots & \dots & \dots & \dots \\ S_{M,1}^{j_1, \dots, j_i, \dots, j_I} & S_{M,2}^{j_1, \dots, j_i, \dots, j_I} & \dots & S_{M,N}^{j_1, \dots, j_i, \dots, j_I} \end{pmatrix}, \quad (10)$$

с весовыми коэффициентами значимости показателей:

$$\mathbf{W}^{j_1, \dots, j_i, \dots, j_I} = \left(W_1^{j_1, \dots, j_i, \dots, j_I}, \dots, W_n^{j_1, \dots, j_i, \dots, j_I}, \dots, W_N^{j_1, \dots, j_i, \dots, j_I} \right), \quad (11)$$

и коэффициентами компетентности МПР:

$$\mathbf{r}^{j_1, \dots, j_i, \dots, j_I} = \left(r_1^{j_1, \dots, j_i, \dots, j_I}, \dots, r_l^{j_1, \dots, j_i, \dots, j_I}, \dots, r_L^{j_1, \dots, j_i, \dots, j_I} \right), \quad (12)$$

первоначальные значения которых совпадают между собой и вычисляются как обратная величина количества МПР:

$$r_l^{j_1, \dots, j_i, \dots, j_I} = \frac{1}{L}, \quad (13)$$

где $r_l^{j_1, \dots, j_i, \dots, j_I}$ – коэффициент компетентности l -го МПР для кортежа $\mathbf{X}^{j_1, \dots, j_i, \dots, j_I}$.

По матрице решений (10) и весовым коэффициентам (11) с использованием коэффициентов компетентности МПР (12) формируется мультимножество выбранных альтернатив:

$$\widehat{\mathbf{A}}^{j_1, \dots, j_i, \dots, j_I} = \left\{ a_1^{j_1, \dots, j_i, \dots, j_I} \cdot A_1, \dots, a_m^{j_1, \dots, j_i, \dots, j_I} \cdot A_m, \dots, a_M^{j_1, \dots, j_i, \dots, j_I} \cdot A_M \right\}, \quad (14)$$

где $\widehat{\mathbf{A}}^{j_1, \dots, j_i, \dots, j_I}$ – мультимножество выбранных альтернатив; $a_m^{j_1, \dots, j_i, \dots, j_I}$ – кратность m -й альтернативы, которая определяется как сумма первоначальных компетентностей (13) тех МПР, которые выбрали ее наилучшей:

$$a_m^{j_1, \dots, j_i, \dots, j_I} = \sum_{l=1}^L \begin{cases} r_l^{j_1, \dots, j_i, \dots, j_I}, & \text{если } F_l(\mathbf{S}^{j_1, \dots, j_i, \dots, j_I}, \mathbf{W}^{j_1, \dots, j_i, \dots, j_I}) = A_m \in \widehat{\mathbf{A}}^{j_1, \dots, j_i, \dots, j_I} \\ 0, & \text{иначе} \end{cases}. \quad (15)$$

Следует отметить, что мультимножество (14) не соответствует своему строгому математическому определению, поскольку кратности вхождения элементов (15) представляют собой целые числа, а его мощность при использовании первоначальных компетентностей (13) равна единице.

Из элементов мультимножества (14) по мажоритарному принципу строится множество наилучших альтернатив, элементы которого имеют максимальное значение кратности вхождения:

$$\tilde{A}^{j_1, \dots, j_i, \dots, j_I} = \operatorname{argmax}_{a_m^{j_1, \dots, j_i, \dots, j_I}} \tilde{A}^{j_1, \dots, j_i, \dots, j_I} = \left\{ A_m \mid a_m^{j_1, \dots, j_i, \dots, j_I} = \max_m \left\{ a_m^{j_1, \dots, j_i, \dots, j_I} > (\geq) z \right\} \right\}, \quad (16)$$

где z – заданная суммарная компетентность участников группового голосования.

Если множество наилучших альтернатив (16) имеет единичную размерность:

$$\dim \tilde{A}^{j_1, \dots, j_i, \dots, j_I} = 1, \quad (17)$$

то для каждого МПР, выбравшего A_m , уточняется значение его первоначального коэффициента компетентности (13) следующим образом:

$$r_l^{j_1, \dots, j_i, \dots, j_I} = \begin{cases} \frac{1}{L}, & \text{если } F_l(\mathbf{S}^{j_1, \dots, j_i, \dots, j_I}, \mathbf{W}^{j_1, \dots, j_i, \dots, j_I}) = A_m \in \tilde{A}^{j_1, \dots, j_i, \dots, j_I} \\ 0, & \text{иначе} \end{cases}, \quad (18)$$

иначе для устранения мультивариантности результата привлекается ЛПР и первоначальное значение коэффициента компетентности (13) уточняется согласно:

$$r_l^{j_1, \dots, j_i, \dots, j_I} = \begin{cases} \frac{1}{L}, & \text{если } F_l(\mathbf{S}^{j_1, \dots, j_i, \dots, j_I}, \mathbf{W}^{j_1, \dots, j_i, \dots, j_I}) = f_{\text{ЛПР}}(\tilde{A}^{j_1, \dots, j_i, \dots, j_I}) \\ 0, & \text{иначе} \end{cases}, \quad (19)$$

где $f_{\text{ЛПР}}$ – функция выбора альтернативы из множества (16), реализуемая ЛПР.

Из формул (18), (19) следует, что при нескольких наилучших альтернативах, выбранных отличающимися МПР, при прочих равных условиях, кратность вхождения в мультимножество (14) будет меньше у той, которая была выбрана МПР с уточненным значением коэффициента компетентности равным нулю.

Таким образом, по всей совокупности (9) кортежей входных переменных задаются первоначальные коэффициенты компетентности (13) и уточняются по (18), (19) для выполнения (17), определяя собой значения J_i -х узлов I -мерных L -сеток для МПР из (6).

Далее по матрице решений (4) и весовым коэффициентам (5) для кортежа входных переменных (3) формируется мультимножество выбранных альтернатив:

$$\widehat{\mathbf{A}}^{set} = \{a_1^{set} \cdot A_1, \dots, a_m^{set} \cdot A_m, \dots, a_M^{set} \cdot A_M\}, \quad (20)$$

где a_m^{set} – кратность m -й альтернативы, которая определяется как сумма коэффициентов компетентности тех МПР, которые выбрали ее наилучшей:

$$a_m^{set} = \sum_{l=1}^L \begin{cases} r_l^{set}, & \text{если } F_l(\mathbf{S}^{set}, \mathbf{W}^{set}) = A_m \in \widehat{\mathbf{A}}^{set} \\ 0, & \text{иначе} \end{cases}. \quad (21)$$

Расчет значения коэффициента компетентности для l -го МПР из (7), входящего в (21), производится по I -мерной локальной линейной интерполяции вида:

$$r_l^{set} = r_l^{j_1, \dots, j_i, \dots, j_I} \cdot N_{00\dots 0} + r_l^{j_1, \dots, j_i, \dots, j_{I+1}} \cdot N_{00\dots 1} + \dots + r_l^{j_1+1, \dots, j_i+1, \dots, j_{I+1}} \cdot N_{11\dots 1}, \quad (22)$$

где $N_{00\dots 0}$, $N_{00\dots 1}$, ..., $N_{11\dots 1}$ – значения полиномов для всевозможного количества способов упорядочивания заданных значений переменных и их границ, определяемые следующим образом:

$$\left\{ \begin{array}{l} N_{00\dots 0} = \frac{(Val_{1,j_1+1} - Val_1^{set}) \cdot (Val_{2,j_2+1} - Val_2^{set}) \cdot \dots \cdot (Val_{I,j_I+1} - Val_I^{set})}{(Val_{1,j_1+1} - Val_{1,j_1}) \cdot (Val_{2,j_2+1} - Val_{2,j_2}) \cdot \dots \cdot (Val_{I,j_I+1} - Val_{I,j_I})} \\ N_{00\dots 1} = \frac{(Val_{1,j_1+1} - Val_1^{set}) \cdot (Val_{2,j_2+1} - Val_2^{set}) \cdot \dots \cdot (Val_I^{set} - Val_{I,j_I})}{(Val_{1,j_1+1} - Val_{1,j_1}) \cdot (Val_{2,j_2+1} - Val_{2,j_2}) \cdot \dots \cdot (Val_{I,j_I+1} - Val_{I,j_I})}, \\ \dots \\ N_{11\dots 1} = \frac{(Val_1^{set} - Val_{1,j_1}) \cdot (Val_2^{set} - Val_{2,j_2}) \cdot \dots \cdot (Val_I^{set} - Val_{I,j_I})}{(Val_{1,j_1+1} - Val_{1,j_1}) \cdot (Val_{2,j_2+1} - Val_{2,j_2}) \cdot \dots \cdot (Val_{I,j_I+1} - Val_{I,j_I})} \end{array} \right. \quad (23)$$

где $r_l^{j_1 \dots j_i \dots j_I}$, $r_l^{j_1 \dots j_i \dots j_I+1}$, ..., $r_l^{j_1+1 \dots j_i+1 \dots j_I+1}$ – уточненные значения коэффициента компетентности для l -го МПП в окружающих точках; Val_{1,j_1} , Val_{1,j_1+1} , Val_{2,j_2} , Val_{2,j_2+1} , ..., Val_{I,j_I} , Val_{I,j_I+1} – значения окружающих точек для 1-й, 2-й, ..., I -й входных переменных соответственно, причем:

$$\left\{ \begin{array}{l} Val_{1,j_1} \leq Val_1^{set} \leq Val_{1,j_1+1} \\ Val_{2,j_2} \leq Val_2^{set} \leq Val_{2,j_2+1} \\ \dots \\ Val_{I,j_I} \leq Val_I^{set} \leq Val_{I,j_I+1} \end{array} \right. \quad (24)$$

Вычисление интерполяционного коэффициента компетентности (22) для l -го МПП в случае I входных переменных (3) использует его уточненное значение в 2^I окружающих точках по (23) из (24).

Из элементов мультимножества (20) по мажоритарному принципу строится множество наилучших альтернатив, элементы которого имеют максимальное значение кратности вхождения:

$$\tilde{\mathbf{A}}^{set} = \operatorname{argmax}_{a_m^{set}} \hat{\mathbf{A}}^{set} = \left\{ A_m \mid a_m^{set} = \max_m \{ a_m^{set} > (\geq) z \} \right\}. \quad (25)$$

Таким образом, размерность множества (25) будет совпадать с единицей, тем самым выполняя требуемое равенство (8), поскольку

рассчитанные значения коэффициентов компетентности для МПР оперируют значениями 2^l окружающих точек из J_i -х узлов l -мерных L -сеток, которые являются уточненными коэффициентами компетентности, или обеспечивающими большинство наилучшей альтернативе A_m из множества (25), или совпадающими с ее выбором для функции $f_{\text{ЛПР}}$.

4. Вычислительный эксперимент. При производстве металлических деталей гальваническое покрытие является важным этапом, обеспечивающим защиту поверхности от коррозии и улучшающим ее эстетические и механические свойства. Процесс гальванизации широко применяется в различных отраслях промышленности (автомобильной, электронной, медицинской и других). Он основан на использовании электролитического раствора, содержащего металлические ионы, которые взаимодействуют с поверхностью детали под действием электрического тока. При этом на поверхности обрабатываемой детали формируется тонкий слой металла. Использование предложенного метода решения поставленной задачи рассмотрено на примере группового принятия решений для выбора варианта технологического процесса нанесения гальванического покрытия. К основным переменным, влияющим на выбор технологии, относится площадь поверхности обрабатываемой детали. Совокупность кортежей входной переменной из дискретных значений внутри допустимого диапазона ее изменения имеет вид:

$$\mathbf{X}^{j_1} = \left(\langle X_1; Val_{1,j_1} \rangle \right), (j_1 = 1, 2, \dots, J_1 = 11), \quad (26)$$

где X_1 – площадь поверхности обрабатываемой детали; Val_{1,j_1} – величина площади поверхности обрабатываемой детали, имеющая диапазон изменения от 10 дм² до 100 дм² с шагом дискретных значений 9 дм².

Альтернативы (1) определяют следующие $M = 7$ вариантов:

$$\mathbf{A} = \{ A_1, A_2, A_3, A_4, A_5, A_6, A_7 \}, \quad (27)$$

для технологического процесса нанесения гальванического покрытия в ванне с: A_1 – анодами, работающими различное время [12]; A_2 – анодами, работающими в циклическом режиме [13]; A_3 – с отключаемыми при реверсировании тока анодами [14]; A_4 – с защитными катодами [15]; A_5 – с токонепроводящими

экранами [16]; A_6 – с биполярными электродами [17]; A_7 – с фигурными анодами [18].

Наличие в гальванической ванне нескольких анодов позволяет отключать их от источника питания в различное время (альтернатива A_1), изменять путь протекания постоянного тока при их циклическом переключении (альтернатива A_2), а также «прямом» и «обратном» режиме электролиза (альтернатива A_3). Расположение в гальванической ванне защитных катодов (альтернатива A_4) дает возможность отвлечь на себя часть наносимого покрытия от обрабатываемой детали (на участках, наиболее близких к аноду). Для защиты выступающих участков детали от протекания через них тока в электролите используются токонепроводящие экраны (альтернатива A_5). Применение биполярных электродов (альтернатива A_6) позволяет направить ток в углубления и «глухие» полости детали. Уменьшение расстояния между анодом и деталью-катодом достигается использованием фигурного анода (альтернатива A_7), имеющего форму, которая повторяет контуры обрабатываемой детали.

Альтернативы (27) оцениваются по следующим $N = 4$ показателям (2):

$$K = \{K_1, K_2, K_3, K_4\}, \quad (28)$$

где K_1 – равномерность распределения толщины гальванического покрытия на поверхности детали; K_2 – производительность гальванической ванны, ч^{-1} ; K_3 – электроэнергия, затрачиваемая на нанесение гальванического покрытия, $\text{Вт} \cdot \text{ч}$; K_4 – стоимость реализации гальванического процесса, руб. Показатели K_1 и K_2 стремятся к максимуму, а показатели K_3 и K_4 – к минимуму.

Объективный выбор технологического процесса из (27) позволит обеспечить высокое качество покрытия (показатель K_1), интенсифицировать процесс (показатель K_2) и существенно снизить затраты на гальваническое производство (показатели K_3 , K_4).

Значения альтернатив (27) по показателям (28) (а)–(г) из матриц решений (10) для (26) приводятся на рисунке 1.

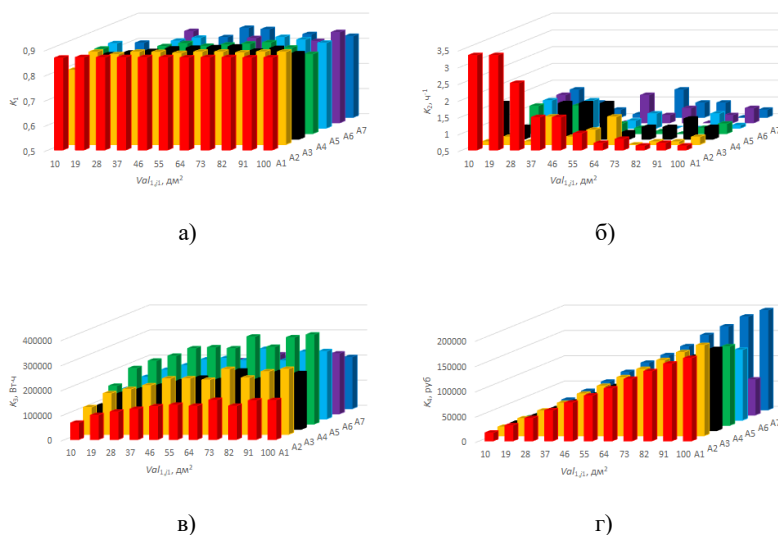


Рис. 1. Значения альтернатив A_1 - A_7 по показателям K_1 - K_4 а)-г) из матриц решений для дискретных значений внутри допустимого диапазона изменения входной переменной

В составе участников группового принятия решений (6) используются следующие $L = 10$ методов:

$$F = \left(\langle nF_1 : F_1(S, W) \rangle, \dots, \langle nF_{10} : F_{10}(S, W) \rangle \right), \quad (29)$$

где nF_1 – оценки аддитивного коэффициента (ARAS) [19]; nF_2 – комбинативной оценки расстояния (CODAS) [20]; nF_3 – комплексной пропорциональной оценки (COPRAS) [21]; nF_4 – оценки расстояния от среднего решения (EDAS) [22]; nF_5 – серого реляционного анализа (GRA) [23]; nF_6 – многокритериальной оптимизации анализа отношений (MOORA) [24]; nF_7 – многокритериальной оптимизации простого анализа отношений (MOOSRA) [25]; nF_8 – простого аддитивного взвешивания (SAW) [26]; nF_9 – предпочтения порядка посредством подобия идеальному решению (TOPSIS) [27]; nF_{10} – оценки взвешенного агрегированного суммарного произведения (WASPAS) [28].

Функция $f_{\text{ГПР}}$ выбирает альтернативу с наименьшим индексом.

Совокупность кортежей заданных значений входной переменной (3) имеет вид:

$$\mathbf{X}^{set} = \left(\left\langle X_i; Val_i^{set} \right\rangle \right), \quad (30)$$

где Val_i^{set} – величина площади поверхности обрабатываемой детали, принимающая следующие значения, дм^2 : 17,2; 26,2; 35,2; 44,2; 53,2; 62,2; 71,2; 80,2; 89,2; 98,2.

Кортежам заданных значений входной переменной (30) соответствуют значения альтернатив (27) по показателям (28) (а)–(г) из матриц решений (4), представленные на рисунке 2.

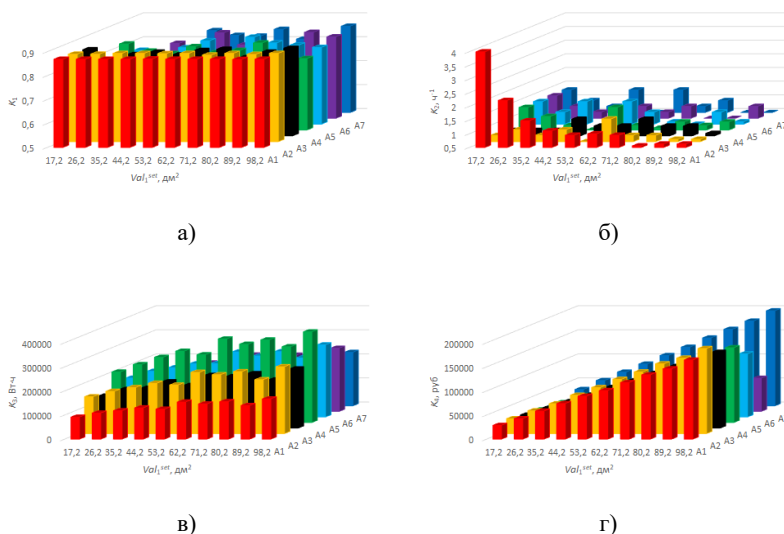


Рис. 2. Значения альтернатив A_1 - A_7 по показателям K_1 - K_4 а)–г) из матриц решений для заданных значений входной переменной

Определение весовых коэффициентов значимости показателей производится по методу из [29]. Метод предполагает формирование матрицы весовых коэффициентов (с использованием количественных подходов), которой сопоставляется матрица рангов (качественный подход). Среди методов количественного подхода используются: равнозначный; энтропийный; стандартного отклонения; основанный на эффектах удаления; корреляции; потери влияния; комплексный; угловой; основанный на коэффициенте Джини; статистической дисперсии. Для получения заданного значения коэффициента согласованности с помощью матрицы рангов решается задача

бинарной оптимизации. Согласованность результатов (найденных ранговых значений весовых коэффициентов) оценивается с помощью коэффициента конкордации Кендалла при заданном уровне значимости. Весовые коэффициенты значимости показателей по матрицам решений (10) для (26) и (4) для (30), найденные для коэффициента согласованности 0,8 при уровне значимости 0,05, показаны на рисунке 3(а) и 3(б) соответственно.

Выбор наилучшей альтернативы при мультивариантности результата осуществляется в (16) и (25) для заданной суммарной компетентности участников группового голосования: 0, 1/2, 2/3 и 3/4, что соответствует относительному, абсолютному, квалифицированному и подавляющему мажоритарному большинству.




Рис. 3. Значения весовых коэффициентов значимости показателей K_1 - K_4 по матрицам решений для совокупности дискретных значений: а) внутри допустимого диапазона изменения входной переменной; б) и заданных значений

В случае получения мультивариантности результата производится дополнительная проверка единственности найденного решения по методу Борда, согласно которому каждый МПР упорядочивает альтернативы, присваивая им баллы от M до 1 (за первое место присуждается M баллов), с последующим взвешенным суммированием баллов у каждого решения с учетом компетентности МПР и выбором наилучшей альтернативы, имеющей наибольшую взвешенную сумму баллов [30]. Компетентность МПР рассчитывается итерационно по степени согласованности его оценок с групповой оценкой альтернатив по достижению точности 0,001.

Сравнение альтернатив по показателям производится в разработанном программном обеспечении на языке Python 3 [31], использующем в своем составе функции из библиотеки ruDecision для реализации многокритериального принятия решений по выбору наилучшей альтернативы согласно МПР из группы (29).

5. Анализ полученных результатов. В таблице 1 приводятся результаты принятия решений для дискретных значений внутри допустимого диапазона изменения входной переменной при равнозначности коэффициентов компетентности МПР.

Таблица 1. Результаты принятия решений для дискретных значений внутри допустимого диапазона изменения входной переменной при равнозначности коэффициентов компетентности МПР

$Val_{1,j1}, \text{ дм}^2$		10	19	28	37	46	55	64	73	82	91	100
Кратности вхождения альтернатив в \tilde{A}^j	a_1	1	1	1	0,9	0,5	0	0	0	0,3	0	0
	a_2	0	0	0	0	0	0	0,3	0	0	0	0
	a_3	0	0	0	0,1	0,5	0,2	0	0	0	0,2	0
	a_4	0	0	0	0	0	0	0	0	0	0	0
	a_5	0	0	0	0	0	0	0	0	0	0	0
	a_6	0	0	0	0	0	0,8	0,2	1	0,6	0,8	1
	a_7	0	0	0	0	0	0	0,5	0	0,1	0	0
\tilde{A}^j	$z=0$	A_1	A_1	A_1	A_1	$A_{1,3}$	A_6	A_7	A_6	A_6	A_6	A_6
	$z=1/2$	A_1	A_1	A_1	A_1	\emptyset	A_6	\emptyset	A_6	A_6	A_6	A_6
	$z=2/3$	A_1	A_1	A_1	A_1	\emptyset	A_6	\emptyset	A_6	\emptyset	A_6	A_6
	$z=3/4$	A_1	A_1	A_1	A_1	\emptyset	A_6	\emptyset	A_6	\emptyset	A_6	A_6
$\text{dim } \tilde{A}^j$	$z=0$	1	1	1	1	2	1	1	1	1	1	1
	$z=1/2$	1	1	1	1	0	1	0	1	1	1	1
	$z=2/3$	1	1	1	1	0	1	0	1	0	1	1
	$z=3/4$	1	1	1	1	0	1	0	1	0	1	1
$f_{\text{ЛПР}}$	$z=0$	-	-	-	-	A_1	-	-	-	-	-	-
	$z=1/2$	-	-	-	-	\nexists	-	\nexists	-	-	-	-
	$z=2/3$	-	-	-	-	\nexists	-	\nexists	-	\nexists	-	-
	$z=3/4$	-	-	-	-	\nexists	-	\nexists	-	\nexists	-	-

Наиболее популярной выбранной альтернативой является A_1 (на первой половине) и A_6 (на второй половине) для дискретных значений внутри допустимого диапазона изменения входной переменной. Ситуация мультивариантности результата встречается 9,09% от количества дискретных значений входных переменных – при $z = 0$ у $Val_{1,j1} = 46 \text{ дм}^2$ множество наилучших альтернатив (16) имеет размерность $\text{dim } \tilde{A}^j = 2$, что требует привлечения $f_{\text{ЛПР}}$. Ситуация отсутствия наилучшей альтернативы в множестве (16) и, как следствие, невозможности принятия решений встречается 18,18%

($Val_{1,j1} = 46 \text{ дм}^2$ и $Val_{1,j1} = 64 \text{ дм}^2$) и 27,27% ($Val_{1,j1} = 46 \text{ дм}^2$, $Val_{1,j1} = 64 \text{ дм}^2$ и $Val_{1,j1} = 82 \text{ дм}^2$) при $z = 1/2$, а также $z = 2/3$ и $z = 3/4$ от количества дискретных значений входной переменной соответственно.

Уточненные коэффициенты компетентности МПР для совокупности коротежей входной переменной из дискретных значений внутри допустимого диапазона ее изменения продемонстрированы на рисунке 4.

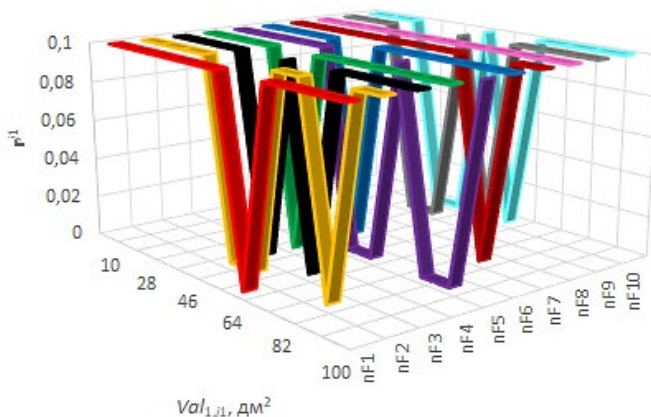


Рис. 4. Уточненные коэффициенты компетентности МПР для совокупности коротежей входной переменной из дискретных значений внутри допустимого диапазона ее изменения

Максимальное среднее значение коэффициента компетентности среди дискретных значений внутри допустимого диапазона изменения входной переменной имеет метод nF_8 , а наименьшее – nF_5 . Коэффициенты компетентности в узловых точках у методов nF_4 и nF_6 , а также nF_9 и nF_{10} совпадают.

В таблице 2 приводятся результаты принятия решений для заданных значений входной переменной при равнозначности (верхняя строка) и расчете (нижняя строка) коэффициентов компетентности МПР. Наиболее популярной выбранной альтернативой также остается A_1 (на первой половине) и A_6 (на второй половине) для заданных значений входной переменной.

Таблица 2. Результаты принятия решений для заданных значений входной переменной при равнозначности (верхняя строка) и расчете (нижняя строка) коэффициентов компетентности МПР

Val_1^{set} , дм ²	17,2	26,2	35,2	44,2	53,2	62,2	71,2	80,2	89,2	98,2	
Кратности вхождения альтернатив в \tilde{A}^{set}	a_1	1	1	1	0,2	0	0,1	0	0	0	0
		1	1	0,92	0,2	0	0,02	0	0	0	0
	a_2	0	0	0	0	0	0	0	0	0	0
		0	0	0	0	0	0	0	0	0	0
	a_3	0	0	0	0	0	0	0	0,3	0	0
		0	0	0	0	0	0	0	0,14	0	0
	a_4	0	0	0	0	0	0	0	0	0	0
		0	0	0	0	0	0	0	0	0	0
	a_5	0	0	0	0	0,9	0	0	0	0,5	0
		0	0	0	0	0,64	0	0	0	0,28	0
	a_6	0	0	0	0	0,1	0,7	1	0,6	0,5	1
		0	0	0	0	0,1	0,44	0,9	0,52	0,48	0,96
	a_7	0	0	0	0,8	0	0,2	0	0,1	0	0
		0	0	0	0,38	0	0,1	0	0,02	0	0
\tilde{A}^{set}	$z=0$	A_1	A_1	A_1	A_7	A_5	A_6	A_6	A_6	A_5, A_6	A_6
		A_1	A_1	A_1	A_7	A_5	A_6	A_6	A_6	A_6	A_6
	$z=1/2$	A_1	A_1	A_1	A_7	A_5	A_6	A_6	A_6	\emptyset	A_6
		A_1	A_1	A_1	\emptyset	A_5	\emptyset	A_6	A_6	\emptyset	A_6
	$z=2/3$	A_1	A_1	A_1	A_7	A_5	A_6	A_6	\emptyset	\emptyset	A_6
		A_1	A_1	A_1	\emptyset	\emptyset	\emptyset	A_6	\emptyset	\emptyset	A_6
	$z=3/4$	A_1	A_1	A_1	A_7	A_5	\emptyset	A_6	\emptyset	\emptyset	A_6
		A_1	A_1	A_1	\emptyset	\emptyset	\emptyset	A_6	\emptyset	\emptyset	A_6
$dim \tilde{A}^{set}$	$z=0$	1	1	1	1	1	1	1	1	2	1
		1	1	1	1	1	1	1	1	1	1
	$z=1/2$	1	1	1	1	1	1	1	1	0	1
		1	1	1	0	1	0	1	1	0	1
	$z=2/3$	1	1	1	1	1	1	1	0	0	1
		1	1	1	0	0	0	1	0	0	1
	$z=3/4$	1	1	1	1	1	0	1	0	0	1
		1	1	1	0	0	0	0	0	0	1
$f_{МП}$	$z=0$	-	-	-	-	-	-	-	-	A_5	-
		-	-	-	-	-	-	-	-	-	-
	$z=1/2$	-	-	-	-	-	-	-	-	\exists	-
		-	-	-	\exists	-	\exists	-	-	\exists	-
	$z=2/3$	-	-	-	-	-	-	-	\exists	\exists	-
		-	-	-	\exists	\exists	\exists	-	\exists	\exists	-
	$z=3/4$	-	-	-	-	-	\exists	-	\exists	\exists	-
		-	-	-	\exists	\exists	\exists	-	\exists	\exists	-

Произведем сравнительный анализ данных альтернатив. Преобладание альтернативы A_1 для нанесения гальванического покрытия на детали меньших размеров объясняется лучшими значениями по показателям K_1-K_3 , поскольку предоставляет: а) возможность динамического изменения распределения тока в

электролите и, как следствие, улучшение равномерности осаждаемого покрытия на поверхности катода (среднее значение $W_1^{set} = 0,128$); б) увеличение силы тока гальванической ванны за счет большей площади анодов и, как следствие, повышение ее производительности (среднее значение $W_2^{set} = 0,414$); в) снижение затрат на электроэнергию (среднее значение $W_3^{set} = 0,231$) поскольку в ванне не присутствуют посторонних электродов, ее потребляющих. Однако по показателю K_4 альтернатива A_1 уступает A_6 , что объясняется ее более высокой стоимостью реализации (среднее значение $W_4^{set} = 0,228$), так как необходимо наличие источника питания с несколькими управляющими и силовыми модулями. Преобладание альтернативы A_6 для нанесения гальванического покрытия на детали больших размеров объясняется снижением стоимости реализации (среднее значение $W_4^{set} = 0,341$), поскольку биполярные электроды изготавливаются из недорогих материалов, таких как углерод или нержавеющей сталь, имеют простую конструкцию и не требуют сложного производства, а также могут использоваться на протяжении длительного времени без необходимости замены. Однако по показателям K_1 - K_3 альтернатива A_6 уступает A_1 , что связано с: а) возможностью улучшения плотности тока только в труднодоступных полостях на катоде и, как следствие, равномерности осаждаемого покрытия не на всей его поверхности (среднее значение $W_1^{set} = 0,047$); б) меньшей производительностью гальванической ванны (среднее значение $W_2^{set} = 0,309$) за счет увеличения ее электрического сопротивления и, как следствие, повышению длительности обработки детали; в) увеличением затрат на электроэнергию (среднее значение $W_3^{set} = 0,304$) из-за создания большей плотности тока на поверхности электродов, что влечет за собой интенсификацию электрохимической реакции, требующей большего количества энергии для ее поддержания.

Ситуация мультивариантности результата не встречается ни разу при расчете коэффициентов компетентности МПР и при их равнозначности встречается в 10% от количества дискретных значений – при $z = 0$ у $Val_{1,j1} = 89,2$ дм² множество наилучших альтернатив (25) имеет размерность $\dim \tilde{A}^{set} = 2$, что требует привлечения $f_{ЛПР}$. Ситуация отсутствия наилучшей альтернативы в множестве (25) и, как следствие, невозможности принятия решений при равнозначности коэффициентов компетентности МПР встречается 10% ($Val_1^{set} = 89,2$ дм²), 20% ($Val_1^{set} = 80,2$ дм² и $Val_1^{set} = 89,2$ дм²) и 30% ($Val_1^{set} = 62,2$ дм², $Val_1^{set} = 80,2$ дм² и $Val_1^{set} = 89,2$ дм²) при $z = 1/2$, $z = 2/3$ и $z = 3/4$ от количества заданных значений входных переменных соответственно. Ситуация отсутствия наилучшей альтернативы

в множестве (25) и, как следствие, невозможности принятия решений при расчете коэффициентов компетентности МПР встречается 30% ($Val_1^{set} = 44,2 \text{ дм}^2$, $Val_1^{set} = 62,2 \text{ дм}^2$ и $Val_1^{set} = 89,2 \text{ дм}^2$) и 50% ($Val_1^{set} = 44,2 \text{ дм}^2$, $Val_1^{set} = 53,2 \text{ дм}^2$, $Val_1^{set} = 62,2 \text{ дм}^2$, $Val_1^{set} = 80,2 \text{ дм}^2$ и $Val_1^{set} = 89,2 \text{ дм}^2$) при $z = 1/2$, а также $z = 2/3$ и $z = 3/4$ от количества заданных значений входных переменных соответственно.

Результаты проверки единственности найденного решения A_6 при мультивариантности результата для $Val_1^{set} = 89,2 \text{ дм}^2$ по методу Борда показаны на рисунке 5. Баллы для альтернатив A_1 - A_7 , полученные в результате их упорядочивания с применением МПР nF_1 - nF_{10} , приводятся на рисунке 5(а). Взвешенные суммарные баллы для альтернатив A_1 - A_7 , рассчитанные с учетом компетентности МПР, демонстрируются на рисунке 5(б).




Рис. 5. Баллы для альтернатив A_1 - A_7 , полученные в результате их: а) упорядочивания с применением МПР nF_1 - nF_{10} ; б) их взвешенные суммарные баллы по методу Борда

Значения коэффициентов компетентности для МПР по предлагаемому и итерационному методам расчета показаны на рисунке 6.




Рис. 6. Значения коэффициентов компетентности для МПР по предлагаемому и итерационному методам расчета

В результате дополнительного расчета наилучшей альтернативой также является A_6 , незначительно превосходя A_5 (6,36 и 6,32 балла соответственно). Однако полученные баллы определяют только порядок расположения альтернатив по показателям сравнения и не дают возможность сделать вывод о том, на сколько или во сколько раз предпочтительнее A_6 по сравнению с A_5 . Предпочтение наилучшей A_6 по набранным баллам может не оправдывать дополнительных затрат или рисков, связанных с выбором этой альтернативы, и привести к необходимости пересмотра данного решения в будущем, так как по сути она располагается на том же месте в ранжировке, что и A_5 . Данное обстоятельство обусловлено незначительным среднеквадратическим отклонением (совпадает с точностью их расчета) значений коэффициентов компетентности МПР, найденных итерационно для метода Борда. Это связано с тем, что используемые МПР основаны на определенных математических принципах и алгоритмах, которые имеют общие черты в своей логике и подходе, и расчет их компетентности, основанный на минимизации расхождения степени согласованности частных оценок с групповой оценкой альтернатив, сходится к решению всего за 2 итерации при равнозначности начальных значений коэффициентов.

В предлагаемом методе альтернатива A_6 превосходит A_5 значительно (0,48 и 0,28 соответственно), что обуславливается большим среднеквадратическим отклонением (0,041) значений коэффициентов компетентности МПР, означающим их большую вариативность, позволяющей лучше оценить степень правильности интерпретации и использования данных из матрицы решений МПР для выбора наилучшей альтернативы.

Таким образом, можно заключить следующее:

1. Мультивариантность результата встречается только по мажоритарному принципу относительного большинства при формировании множества наилучших альтернатив.

2. Разрешение ситуации мультивариантности результата без уточнения коэффициентов компетентности участников голосования (при их равнозначности) возможно только с привлечением функции выбора альтернативы, реализуемой ЛПР.

3. Расчет коэффициентов компетентности участников голосования через локальную линейную интерполяцию по их уточненным значениям в окружающих точках позволяет в 100% случаев осуществлять выбор наилучшей альтернативы при мультивариантности результата.

4. Найденные коэффициенты компетентности обладают лучшей вариативностью, обеспечивающей бóльшую значимость выбранной альтернативе.

5. Мажоритарный принцип абсолютного, квалифицированного и подавляющего большинства в 10-50% случаев вызывает ситуацию отсутствия решения в сформированном множестве наилучших альтернатив, которую не способно преодолеть ни равнозначность коэффициентов компетентности участников голосования с привлечением функции выбора альтернативы, реализуемой ЛПР, ни расчет коэффициентов компетентности МПР через локальную линейную интерполяцию по их уточненным значениям в окружающих точках.

6. Заключение. Применение коэффициентов компетентности участников группового принятия решений представляет собой важный инструмент для выбора наилучшей альтернативы в условиях мультивариантности результата и способствует повышению доверия к процессу принятия решений, поскольку позволяет отдать предпочтение альтернативам, выбранным участниками с более высокими значениями соответствующих коэффициентов. В результатах исследования показано, что предложенный метод расчета коэффициентов компетентности участников группового принятия решений через локальную линейную интерполяцию является наиболее эффективным для выбора наилучшей альтернативы при мультивариантности результата по мажоритарному принципу относительного большинства. Программная реализация данного метода позволяет автоматизировать расчет коэффициентов компетентности, упрощающий и ускоряющий получение результата, а также сохранять и анализировать данные о принятии решений, что может быть полезно для последующих исследований и улучшения процессов группового голосования.

Литература

1. Смирнов А.В., Молл Е.Г., Тесля Н.Н. Использование нечетких коалиционных игр при принятии социально ориентированных решений при госпитализации в условиях пандемии // Информатика и автоматизация. 2021. Т. 20. № 5. С. 1090–1114.
2. Шилов Н.Г., Пономарев А.В., Смирнов А.В. Анализ методов онтолого-ориентированного нейро-символического интеллекта при коллаборативной поддержке принятия решений // Информатика и автоматизация. 2023. Т. 22. № 3. С. 576–615.
3. Ларичев О.И. Объективные модели и субъективные решения // М.: Наука. 1987. 143 с.
4. Гуцин Ю.Г., Парфенова М.Я., Парфенов И.И. Многокритериальная задача принятия решений с объективными и субъективными моделями // Вестник

- Ижевского государственного технического университета. 2007. № 3(35). С. 148–150.
5. Gomes M.I., Martins N.C. *Mathematical Models for Decision Making with Multiple Perspectives: An Introduction* // Boca Raton: CRC Press. 2022. 300 p.
 6. Набатова Д.С. Математические и инструментальные методы поддержки принятия решений // М.: Издательство Юрайт. 2023. 292 с.
 7. Biswas S. Measuring performance of healthcare supply chains in India: A comparative analysis of multi-criteria decision making methods // *Decision Making Applications in Management and Engineering*. 2020. vol. 3. no. 2. pp. 162–189.
 8. Hezer S., Gelmez E., Ozceylan E. Comparative analysis of TOPSIS, VIKOR and COPRAS methods for the COVID-19 regional safety assessment // *Journal of Infection and Public Health*. 2021. vol. 14. no. 6. pp. 775–786.
 9. Pramanik P.K.D., Biswas S., Pal S., Marinkovic D., Choudhury P.A. A Comparative Analysis of Multi-Criteria Decision-Making Methods for Resource Selection in Mobile Crowd Computing // *Symmetry*. 2021. vol. 13. no. 9. pp. 1–51. DOI: 10.3390/sym13091713.
 10. Малтугуева Г.С., Юрин А.Ю. Метод поддержки принятия решений в малых группах // *Вестник Бурятского государственного университета. Математика, информатика*. 2012. № 1. С. 26–34.
 11. Колпакова Т.А. Определение компетентности экспертов при принятии групповых решений // *Радиоэлектроника, информатика, управление*. 2011. № 1(24). С. 40–43.
 12. Dutov A.V., Litovka Y.V., Nesterov V.A., Solovjev D.S., Solovjeva I.A., Sypalo K.I. Search for the optimal control over current regimes in electroplating processes with multi anodes at a diversified assortment of treated articles // *Journal of Computer and Systems Sciences International*. 2019. vol. 58. pp. 75–85.
 13. Solovjev D.S., Solovjeva I.A., Konkina V.V., Litovka Y.V. Improving the uniformity of the coating thickness distribution during electroplating treatment of products using multi anode baths // *Materials Today: Proceedings*. 2019. vol. 19. no. 5. pp. 1895–1898.
 14. Solovjev D.S., Potlov A.Y., Litovka Y.V. Reduction of nonuniformity in the thickness of a galvanic coating using disableable anode sections under current reversal conditions // *Theoretical Foundations of Chemical Engineering*. 2019. vol. 53. no. 1. pp. 97–106.
 15. Solovjev D.S., Solovjeva I.A., Konkina V.V. Software Development for the Optimal Parts Location in the Bath Space with the Purpose to Reduce the Non-uniformity of the Coating Thickness // *Proceedings of the 6th International Conference on Industrial Engineering (ICIE 2020)*. 2021. pp. 85–93.
 16. Пчелинцева И.Ю., Литовка Ю.В. Система автоматизированного управления процессом нанесения гальванического покрытия в ванне с токонепроводящим экраном // *Мехатроника, автоматизация, управление*. 2022. Т. 23. № 4. С. 188–196.
 17. Karimian N., Hashemi P., Afkhami A., Bagheri H. The principles of bipolar electrochemistry and its electroanalysis applications // *Current Opinion in Electrochemistry*. 2019. vol. 17. pp. 30–37.
 18. Yang G., Deng D., Zhang Y., Zhu Q., Cai J. Numerical Optimization of Electrodeposition Thickness Uniformity with Respect to the Layout of Anode and Cathode // *Electrocatalysis*. 2021. vol. 12. no. 5. pp. 478–488.
 19. Liu N., Xu Z. An overview of ARAS method: Theory development, application extension, and future challenge // *International Journal of Intelligent Systems*. 2021. vol. 36. no. 7. pp. 3524–3565.

20. Goswami S.S., Jena S., Behera D.K. Implementation of CODAS MCDM Method for the Selection of Suitable Cutting Fluid // 2021 International Conference on Simulation, Automation & Smart Manufacturing (SASM), Mathura, India. 2021. pp. 1–6.
21. Krishankumar R., Garg H., Arun K., Saha A., Ravichandran K.S., Kar S. An integrated decision-making COPRAS approach to probabilistic hesitant fuzzy set information // Complex & Intelligent Systems. 2021. vol. 7. pp. 2281–2298.
22. Yazdani M., Torkayesh A.E., Santibanez-Gonzalez E.D., Otaghsara S.K. Evaluation of renewable energy resources using integrated Shannon Entropy–EDAS model // Sustainable Operations and Computers. 2020. vol. 1. pp. 35–42.
23. Shil B., Sinha P., Das S., Tripathy B.C., Poojary P. Grey Relational Analysis–Based MADM Strategy Under Possibility Environment and Its Application in the Identification of Most Important Parameter Affecting Climate Change and the Impact of Urbanization on Hydropower Plants // Process Integration and Optimization for Sustainability. 2023. vol. 7. no. 3. pp. 599–608.
24. Ic Y.T. A multi-objective credit evaluation model using MOORA method and goal programming // Arabian Journal for Science and Engineering. 2020. vol. 45. no. 3. pp. 2035–2048.
25. Altin H. A Comparison of Performance Results Of Aras And Moosra Methods: American Continent Countries // Journal of Economics, Finance and Accounting. 2020. vol. 7. no. 2. pp. 173–186.
26. Warnars H.L.H.S., Fahrudin A., Utomo W.H. Student performance prediction using simple additive weighting (SAW) method // International Journal of Artificial Intelligence. 2020. vol. 9. no. 1. DOI: 10.11591/ijai.v9.i4.
27. Chakraborty S. TOPSIS and Modified TOPSIS: A comparative analysis // Decision Analytics Journal. 2022. vol. 2. no. 100021. pp. 1–7.
28. Pamucar D., Sremac S., Stevic Z., Cirovic G., Tomic D. New multi-criteria LNN WASPAS model for evaluating the work of advisors in the transport of hazardous goods // Neural Computing and Applications. 2019. vol. 31. pp. 5045–5068.
29. Соловьев Д.С. Метод объективизации значений весовых коэффициентов для принятия решений в многокритериальных задачах // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 1. С. 161–168.
30. Saari D.G. Selecting a voting method: the case for the Borda count // Constitutional Political Economy. 2023. vol. 34. no. 3. pp. 357–366.
31. Соловьев Д.С. Выбор единственной альтернативы с использованием совокупности методов принятия решений при мультивариантности результата в многокритериальных задачах // Свидетельство о государственной регистрации программы для ЭВМ № 2023612846 от 08.02.2023. Заявка № 2023611961 от 08.02.2023.

Соловьев Денис Сергеевич — канд. техн. наук, доцент кафедры, кафедра математического моделирования и информационных технологий, Тамбовский государственный университет имени Г.Р. Державина. Область научных интересов: системный анализ, математическое и компьютерное моделирование, автоматизация и интеллектуализация, поддержка принятия решений и управление сложными системами. Число научных публикаций — 125. solovjevdenis@mail.ru; улица Интернациональная, 33, 392036, Тамбов, Россия; р.т.: +7(4752)723-434 доб. 2021.

Поддержка исследований. Работа выполнена с использованием оборудования центра коллективного пользования научным оборудованием ТГУ имени Г.Р. Державина.

D. SOLOVJEV

COMPETENCE COEFFICIENTS CALCULATION METHOD OF PARTICIPANTS IN GROUP DECISION-MAKING FOR SELECTING THE BEST ALTERNATIVE WITH THE MULTIVARIATE OF THE RESULT

Solovjev D. Competence Coefficients Calculation Method of Participants in Group Decision-Making for Selecting the Best Alternative with the Multivariate of the Result.

Abstract. The problem of obtaining the best alternative using decision-making methods based on the experience of specialists and mathematical calculations is considered in the article. Group decision-making is appropriate for solving this problem. However, it can lead to the selection of several best alternatives (multivariate of the result). Accounting for competence will prioritize the decision of more competent participants and eliminate the emergence of several best alternatives in the process of group decision-making. The problem of determining the competence coefficients for participants in group decision-making has been formulated. The selection of the best alternative with the multivariate of the result is provided in the problem. A method for solving the problem has been developed. It involves discretizing the range of input variables and refining the competence coefficients values of group decision-making participants in it to select the best alternative, either by the majority principle or with the decision-maker's involvement. Further calculation of the competence coefficients for participants in group decision-making is carried out using local linear interpolation of the refined competence coefficient at surrounding points from the discretized range. The use of the proposed method for solving the problem is considered using the example of group decision-making according to the main types of the majoritarian principle for selecting an electrodeposition variant. The results show that the proposed method for calculating the competence coefficients of participants in group decision-making through local linear interpolation is the most effective for selecting the best alternative with a multivariate result based on the relative majority.

Keywords: competence coefficients, group decision-making, selection of the best alternative, multivariate of the result.

References

1. Smirnov A., Moll E., Teslya N. [Use of Fuzzy Coalition Games in Socially Oriented Decision Making During Hospitalization in Pandemic]. *Informatika i avtomatizaciya – Informatics and Automation*. 2021. vol. 20. no. 5. pp. 1090–1114. (In Russ.).
2. Shilov N., Ponomarev A., Smirnov A. [The Analysis of Ontology-Based Neuro-Symbolic Intelligence Methods for Collaborative Decision Support]. *Informatika i avtomatizaciya – Informatics and Automation*. 2023. vol. 22. no. 3. pp. 576–615. (In Russ.).
3. Larichev O.I. *Ob"ektivnye modeli i sub"ektivnye resheniya [Objective Models and Subjective Decisions]*. M.: Nauka. 1987. 143 p. (In Russ.).
4. Gushchin Yu.G., Parfenova M.Ya., Parfenov I.I. [Multi-criteria decision-making problem with objective and subjective models]. *Vestnik Iževskogo gosudarstvennogo tehničeskogo universiteta – Bulletin of Kalashnikov ISTU*. 2007. no. 3(35). pp. 148–150. (In Russ.).
5. Gomes M.L., Martins N.C. *Mathematical Models for Decision Making with Multiple Perspectives: An Introduction*. Boca Raton: CRC Press. 2022. 300 p.

6. Nabatova D.S. Matematicheskie i instrumental'nye metody podderzhki prinyatiya reshenij [Mathematical and instrumental methods of decision support]. M.: Publishing URAIT. 2023. 292 p. (In Russ.).
7. Biswas S. Measuring performance of healthcare supply chains in India: A comparative analysis of multi-criteria decision making methods. *Decision Making Applications in Management and Engineering*. 2020. vol. 3. no. 2. pp. 162–189.
8. Hezer S., Gelmez E., Ozceylan E. Comparative analysis of TOPSIS, VIKOR and COPRAS methods for the COVID-19 regional safety assessment. *Journal of Infection and Public Health*. 2021. vol. 14. no. 6. pp. 775–786.
9. Pramanik P.K.D., Biswas S., Pal S., Marinkovic D., Choudhury P.A. A Comparative Analysis of Multi-Criteria Decision-Making Methods for Resource Selection in Mobile Crowd Computing. *Symmetry*. 2021. vol. 13. no. 9. pp. 1–51. DOI: 10.3390/sym13091713.
10. Maltugueva G.S., Yurin A.Y. [Method of decision-making in small groups]. *Vestnik Buryatskogo gosudarstvennogo universiteta. Matematika, informatika – BSU bulletin. Mathematics, Informatics*. 2012. no. 1. pp. 26–34. (In Russ.).
11. Kolpakova T.A. [Determining the competence of experts in making group decisions]. *Radioelektronika, informatika, upravlenie – Radio Electronics, Computer Science, Control*. 2011. vol. 1(24). pp. 40–43. (In Russ.).
12. Dutov A.V., Litovka Y.V., Nesterov V.A., Solovjev D.S., Solovjeva I.A., Sypalo K.I. Search for the optimal control over current regimes in electroplating processes with multi anodes at a diversified assortment of treated articles. *Journal of Computer and Systems Sciences International*. 2019. vol. 58. pp. 75–85.
13. Solovjev D.S., Solovjeva I.A., Konkina V.V., Litovka Y.V. Improving the uniformity of the coating thickness distribution during electroplating treatment of products using multi anode baths. *Materials Today: Proceedings*. 2019. vol. 19. no. 5. pp. 1895–1898.
14. Solovjev D.S., Potlov A.Y., Litovka Y.V. Reduction of nonuniformity in the thickness of a galvanic coating using disableable anode sections under current reversal conditions. *Theoretical Foundations of Chemical Engineering*. 2019. vol. 53. no. 1. pp. 97–106.
15. Solovjev D.S., Solovjeva I.A., Konkina V.V. Software Development for the Optimal Parts Location in the Bath Space with the Purpose to Reduce the Non-uniformity of the Coating Thickness. *Proceedings of the 6th International Conference on Industrial Engineering (ICIE 2020)*. 2021. pp. 85–93.
16. Pchelintseva I.Yu., Litovka Yu.V. [Automated Control System for the Process of Electroplating in a Bath with a Non-Conductive of Electric Current Screen]. *Mekhatronika, Avtomatizatsiya, Upravlenie – Mechatronics, automation, control*. 2022. vol. 23. no. 4. pp. 188–196. (In Russ.).
17. Karimian N., Hashemi P., Afkhami A., Bagheri H. The principles of bipolar electrochemistry and its electroanalysis applications. *Current Opinion in Electrochemistry*. 2019. vol. 17. pp. 30–37.
18. Yang G., Deng G., Zhang Y., Zhu Q., Cai J. Numerical Optimization of Electrodeposition Thickness Uniformity with Respect to the Layout of Anode and Cathode. *Electrocatalysis*. 2021. vol. 12. no. 5. pp. 478–488.
19. Liu N., Xu Z. An overview of ARAS method: Theory development, application extension, and future challenge. *International Journal of Intelligent Systems*. 2021. vol. 36. no. 7. pp. 3524–3565.
20. Goswami S.S., Jena S., Behera D.K. Implementation of CODAS MCDM Method for the Selection of Suitable Cutting Fluid. *2021 International Conference on Simulation, Automation & Smart Manufacturing (SASM), Mathura, India*. 2021. pp. 1–6.

21. Krishankumar R., Garg H., Arun K., Saha A., Ravichandran K.S., Kar S. An integrated decision-making COPRAS approach to probabilistic hesitant fuzzy set information. *Complex & Intelligent Systems*. 2021. vol. 7. pp. 2281–2298.
22. Yazdani M., Torkayesh A.E., Santibanez-Gonzalez E.D., Otaghsara S.K. Evaluation of renewable energy resources using integrated Shannon Entropy–EDAS model. *Sustainable Operations and Computers*. 2020. vol. 1. pp. 35–42.
23. Shil B., Sinha P., Das S., Tripathy B.C., Poojary P. Grey Relational Analysis–Based MADM Strategy Under Possibility Environment and Its Application in the Identification of Most Important Parameter Affecting Climate Change and the Impact of Urbanization on Hydropower Plants. *Process Integration and Optimization for Sustainability*. 2023. vol. 7. no. 3. pp. 599–608.
24. Ic Y.T. A multi-objective credit evaluation model using MOORA method and goal programming. *Arabian Journal for Science and Engineering*. 2020. vol. 45. no. 3. pp. 2035–2048.
25. Altin H. A Comparison of Performance Results Of Aras And Moosra Methods: American Continent Countries. *Journal of Economics, Finance and Accounting*. 2020. vol. 7. no. 2. pp. 173–186.
26. Warnars H.L.H.S., Fahrudin A., Utomo W.H. Student performance prediction using simple additive weighting (SAW) method. *International Journal of Artificial Intelligence*. 2020. vol. 9. no. 1. DOI: 10.11591/ijai.v9.i4.
27. Chakraborty S. TOPSIS and Modified TOPSIS: A comparative analysis. *Decision Analytics Journal*. 2022. vol. 2. no. 100021. pp. 1–7.
28. Pamucar D., Sremac S., Stevic Z., Cirovic G., Tomic D. New multi-criteria LNN WASPAS model for evaluating the work of advisors in the transport of hazardous goods. *Neural Computing and Applications*. 2019. vol. 31. pp. 5045–5068.
29. Solovjev D.S. [The objectification method of the weight coefficients for decision-making in multicriteria problems]. *Nauchno-tehnicheskij vestnik informacionnyh tekhnologij, mekhaniki i optiki – Scientific and Technical Journal of Information Technologies, Mechanics and Optics*. 2023. vol. 23. no. 1. pp. 161–168. (In Russ.).
30. Saari D.G. Selecting a voting method: the case for the Borda count. *Constitutional Political Economy*. 2023. vol. 34. no. 3. pp. 357–366.
31. Solovjev D.S. The choice of a single alternative using a set of decision-making methods with multivariate results in multicriteria problems. *Computer program registration certificate no. 2023612846 dated 08.02.2023*. (In Russ.).

Solovjev Denis — Ph.D., Associate professor of the department, Department of mathematical modeling and information technologies, Derzhavin Tambov State University. Research interests: system analysis, mathematical and computer modeling, automation and intellectualization, decision support and control of complex systems. The number of publications — 125. solovjevdenis@mail.ru; 33, Internacional'naya St., 392036, Tambov, Russia; office phone: +7(4752)723-434 ext. 2021.

Acknowledgements. The research is carried out using the equipment of the Center for Collective Use of Scientific Equipment of TSU named after G.R. Derzhavin.

А.В. ПАРШУТКИН, Д.И. БУЧИНСКИЙ, Ю.Н. КОПАЛОВ
**МОДЕЛЬ ФУНКЦИОНИРОВАНИЯ КАНАЛА СПУТНИКОВОЙ
СВЯЗИ В УСЛОВИЯХ ЭПИЗОДИЧЕСКОЙ СИНХРОНИЗАЦИИ
С ПОТОКАМИ ИМПУЛЬСНЫХ ПОМЕХ**

Паршуткин А.В., Бучинский Д.И., Копалов Ю.Н. Модель функционирования канала спутниковой связи в условиях эпизодической синхронизации с потоками импульсных помех.

Аннотация. В статье исследуется влияние непреднамеренных импульсных помех на прием информации в условиях эпизодической синхронизации кадров физического уровня канала спутниковой связи с потоками импульсов помех. Предложена аналитическая модель влияния непреднамеренных импульсных помех на прием информации в спутниковом канале связи в условиях эпизодической синхронизации кадров физического уровня с потоками импульсных помех. На примере стандарта DVB-S2 показано совместное влияние шума и непреднамеренных импульсных помех на условные вероятности ошибок при приеме синхрогруппы, служебной части заголовка и информационной части кадра. Приведены оценки среднего числа кадров физического уровня на длительности интервала эпизодической синхронизации, числа интервалов эпизодической синхронизации и доли элементарных посылок в кадре, подвергшихся воздействию помехи, в зависимости от скважности импульсной помехи. Показано, что существуют такие соотношения между длительностью импульса помехи и скважностью ее следования, при которых явление эпизодической синхронизации кадров физического уровня с потоком импульсных помех оказывает существенное влияние на функционирование канала спутниковой связи. Получены зависимости вероятности ошибочного приема кадра физического уровня канала спутниковой связи от отношения сигнал/помеха при фиксированном отношении сигнал/шум и от длительности импульса помехи. Установлено, что при высоких отношениях сигнал/помеха и длительности помехи, соотносимой с длительностью служебной части кадра, но значительно меньше длительности кадра, вероятность ошибочного приема кадра может быть выше, чем при более низких отношениях сигнал/помеха за счет ошибок при приеме служебной части кадров.

Ключевые слова: эпизодическая синхронизация, непреднамеренные импульсные помехи, DVB, помехоустойчивость, широкополосная спутниковая связь.

1. Введение. Функционирование современных систем связи и передачи данных происходит в условиях воздействия естественных фоновых шумов окружающего пространства, промышленных помех и непреднамеренных помех, создаваемых передатчиками других радиоэлектронных средств и систем. Широкое распространение стационарных и подвижных радиолокационных систем приводит к тому, что импульсные сигналы высокой интенсивности остаются существенным фактором, влияющим на электромагнитную совместимость радиоэлектронных средств. Существующие радиолокационные системы обеспечения движения используют диапазоны частот от сотен МГц до сотен ГГц и могут размещаться на

подвижных носителях: воздушных, морских и даже на легковых автомобилях. Как правило, их передатчики имеют высокую среднюю мощность и импульсные режимы работы. Когда ширина спектра импульса помехи существенно превышает ширину спектра сигнала, помеха может быть рассмотрена как импульс шума с равномерным спектром в полосе частот сигнала.

Исследованию влияния импульсных помех на работу систем связи и передачи данных и разработке мер обеспечения защиты от подобных помех посвящено достаточно много теоретических и прикладных работ [1 – 8]. Традиционные подходы к борьбе с импульсными помехами описаны в классических трудах [1, 2]. Для обеспечения приема дискретных сообщений в каналах с сосредоточенными по спектру и импульсными помехами используются нелинейные ограничители и блокирование приемника, компенсация помех, разнесенный прием и помехоустойчивое кодирование.

В современных системах цифровой связи для ослабления влияния помех используется канальное кодирование. В работе [5] рассмотрена возможность применения помехоустойчивого кодирования с перемежением для борьбы с замираниями или другими причинами, приводящими к возникновению групповых ошибок при приеме.

В связи с тем, что методики оценки влияния непреднамеренных помех, как правило, ориентируются на средние значения мощностей помех, то в ряде случаев может возникать недооценка опасности импульсных помех. Данное свойство импульсных помех было отмечено в работе [9]. В работе [10] показано, как данный эффект проявляется в случае воздействия импульсных помех на информационную часть кадра, передаваемого в стандарте широкополосной передачи данных *DVB*.

В отличие от замираний сигнала, связанных с интерференцией электромагнитных волн при многолучевом распространении и возникающих в случайные моменты времени, импульсные помехи, как правило, представляют собой совокупность некоторого числа потоков радиопульсов. При этом поток радиопульсов, создаваемый каждой отдельной радиолокационной системой можно считать на ограниченном интервале времени периодическим. Поскольку при передаче информации используются кадры, которые даже в адаптивных протоколах передачи информации на достаточно протяженных интервалах времени имеют фиксированную длительность, то возможно возникновение интервалов времени, на

которых возникает синхронизация частот следования кадров и поступления помех на вход приемного устройства системы связи. В работах [11, 12] исследовано влияние помех на процесс приема заголовков кадров физического уровня стандарта широкополосной передачи данных *DVB* и показано, что синхронные с заголовками кадра помехи более опасны, чем исследованные ранее асинхронные помехи.

Параметры потоков радиолокационных сигналов имеют длительности импульсов от десятков наносекунд до сотен миллисекунд и частоту повторения от 200 до 4000 Гц. Такие излучения, оказывая влияние на прием сигналов широкополосной спутниковой связи, не могут быть строго синхронными с заголовками кадров физического уровня, имеющими длительность от единиц микросекунд и до сотен микросекунд и период повторения от сотен микросекунд и до десятков миллисекунд. Поэтому модель синхронных помех [13] не вполне адекватно описывает реальную ситуацию воздействия радиолокационных импульсных излучений на прием сигналов широкополосной спутниковой связи. Более корректная модель должна предполагать не точную, а эпизодически возникающую синхронизацию.

Цель работы: исследование влияния импульсных помех на прием информации в условиях эпизодической синхронизации кадров физического уровня канала спутниковой связи с потоками радиоимпульсов непреднамеренных помех.

2. Аналитическая оценка влияния импульсных помех на прием информации в спутниковом канале связи в условиях эпизодической синхронизации с потоками импульсных помех. Под эпизодической синхронизацией кадров физического уровня канала спутниковой связи с потоками импульсных помех будем понимать такую ситуацию, когда воздействие импульсной помехи совпадает во времени с приемом служебной части кадра физического уровня в течение некоторого числа периодов повторения кадров.

В современных приемниках спутниковых систем связи предусмотрено два режима работы блока кадровой синхронизации – «режим поиска» и «режим захвата». В «режиме поиска» блок синхронизации осуществляет корреляционное сравнение всех поступающих отсчетов с синхрогруппой. Порог принятия решения об обнаружении синхрогруппы в этом режиме устанавливается относительно высоким для уменьшения вероятности ложной тревоги. После обнаружения и успешного приёма одного или нескольких кадров, блок кадровой синхронизации переходит в «режим захвата».

В этом режиме, за счет использования информации из принятых кадров о времени появления следующего кадра, производится корреляционное сравнение с синхрогруппой лишь тех отсчетов принимаемого сигнала, где ожидается её появление. Порог принятия решения о наличии в принятых отсчетах синхрогруппы в «режиме захвата» выбирается существенно меньшим. В случае если в проверяемых отсчетах не будет обнаружена синхрогруппа, блок кадровой синхронизации переходит обратно в «режим поиска» и снова начинает проверять все принимаемые отсчеты с установленным для данного режима порогом обнаружения. Относительно невысокий порог обнаружения синхрогруппы в «режиме захвата» снижает вероятность пропуска кадра, а корреляционная обработка лишь части поступающих отсчетов позволяет сохранить вероятность ложной тревоги не высокой.

Помехоустойчивость блока кадровой синхронизации существенно выше в «режиме захвата», так как низкий порог обнаружения синхрогруппы позволяет принять правильное решение при приеме достаточно большого количества искаженных непреднамеренными помехами символов. Поэтому импульсные помехи с эпизодической синхронизацией для приемников с вышеописанным алгоритмом работы блока кадровой синхронизации особенно опасны, так как потеря кадра при воздействии помехи за счет ошибки в приеме синхрогруппы переводит блок кадровой синхронизации в менее помехоустойчивый «режим поиска». Так потеря синхронизации за счет воздействия импульсной помехи из начала эпизодически синхронизированной пачки помеховых импульсов приведет к более высокой вероятности потери кадров при воздействии последующих помеховых импульсов, из-за снижения помехоустойчивости блока кадровой синхронизации в «режиме поиска».

Поэтому рассмотрим ситуацию, когда входная реализация $y(t)$ приемника системы спутниковой связи представляет собой аддитивную смесь сигнала $s(t)$, импульсной помехи $p(t)$ и совокупности канальных шумов и собственных шумов приемника $n(t)$:

$$y(t) = s(t) + p(t) + n(t). \quad (1)$$

Импульсную помеху представим периодической последовательностью импульсов шума длительностью τ_p и периодом повторения T_p :

$$p(t) = \begin{cases} \chi(t), & \text{при } jT_p \leq t \leq (jT_p + \tau_p); \\ 0, & \text{при } (jT_p + \tau_p) < t < (j+1)T_p, \end{cases} \quad (2)$$

где $\chi(t)$ – шумовой случайный процесс с нулевым математическим ожиданием и среднеквадратичным отклонением σ , $j=0, \pm 1, \pm 2, \dots$

Информационный сигнал $s(t)$ состоит из кадров длительностью T_k включающих N_k элементарных посылок длительностью τ , $T_k = N_k \tau$. В свою очередь, как было показано в [14], кадр стандарта *DVB-S2* включает части с разной помехоустойчивостью: синхрогруппу, служебную часть заголовка кадра и блок передаваемой информации из N_c , N_3 и N_n посылки соответственно:

$$N_k = N_c + N_3 + N_n. \quad (3)$$

При этом одно из допущений, принятых в исследовании, заключается в том, что на отдельный кадр сигнала воздействует не более одного импульса помехи.

Оценим некоторые параметры эпизодической синхронизации на ограниченном интервале следования L кадров с учетом случайного начального положения импульса помехи, а именно среднее число кадров физического уровня на отдельном интервале эпизодической синхронизации M_{cp} , число интервалов эпизодической синхронизации N_M и долю общего числа элементарных посылок, подвергшихся воздействию помехи N_{nL} :

$$N_{nL} = \begin{cases} \frac{\sum_{i=1}^L N_{cni}}{N_c L} & \text{для синхрогруппы} \\ \frac{\sum_{i=1}^L N_{3ni}}{N_3 L} & \text{для служебной части заголовка кадра} \end{cases}, \quad (4)$$

где N_{cni} – число элементарных посылок синхрогруппы i -го кадра, а, N_{3ni} – число элементарных посылок служебной части заголовка i -го кадра, подвергшихся воздействию помехи.

Временная диаграмма огибающих помехи, синхрогрупп и служебных частей заголовков кадров с обозначением интервалов

эпизодической синхронизации помехи с кадрами физического уровня канала спутниковой связи показана на рисунке 1.




Рис. 1. Временная диаграмма огибающих помехи, синхрогрупп и служебных частей заголовков кадров

В структуре кадра на рисунке 1 обозначены красным цветом синхрогруппы, синим цветом служебные части заголовков кадра, зеленым цветом обозначен блок передаваемой информации. Таким же цветом обозначены интервалы эпизодической синхронизации с соответствующей частью кадра. Обозначения на рисунке соответствуют выражениям (1) – (4). Под интервалом синхронизации понимается такой интервал времени следования кадров, в который служебные части каждого кадра сигнала подряд совпадают во временной области с импульсами помехи.

Рассмотрим *частный* пример возникновения условий эпизодической синхронизации помехи с различными частями кадра стандарта DVB-S2. Пусть на интервале, включающем $L = 100$ кадров, τ_p принимает значения $(N_c + N_3)\tau$, $0,125N_k\tau$, $0,25N_k\tau$.

Введем обозначения: φ – номер элементарной посылки первого кадра интервала, соответствующий началу первого импульса помехи, $M_{н\varphi} = M_{сп}/L$ – нормированное значение среднего числа кадров физического уровня на отдельном интервале эпизодической

синхронизации, $M_n = \frac{\sum_{\varphi=1}^{N_k} M_{н\varphi}}{N_k}$, $N_{н\varphi} = N_M/L$ – нормированное значение числа интервалов эпизодической синхронизации на интервале,

включающем L кадров, $N_n = \frac{\sum_{\varphi=1}^{N_k} N_{n\varphi}}{N_k}$, $Q = T_p/\tau_p$ – скважность следования импульсов помехи.

На рисунках 2–7 представлены зависимости параметров эпизодической синхронизации от скважности следования импульсов помехи и ее начального положения для выбранных значений длительности импульса помехи. При этом сплошной линией обозначены значения параметров эпизодической синхронизации с синхрогруппой, а штриховой линией – эпизодической синхронизации с заголовком кадра (в тех случаях, когда данные значения совпадают для синхрогруппы и заголовка, приводится только один график).




Рис. 2. Зависимости нормированного значения среднего числа кадров физического уровня на отдельном интервале эпизодической синхронизации от скважности импульсной помехи при: а) $\tau_p = (N_c + N_3)\tau$, б) $\tau_p = 0,125N_k\tau$, в) $\tau_p = 0,25N_k\tau$


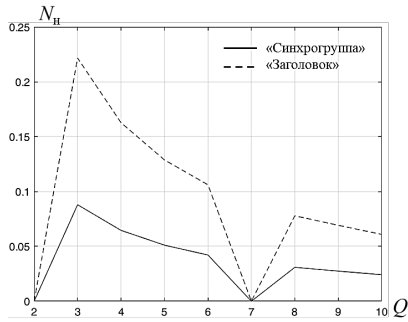


Рис. 3. Зависимости нормированного значения среднего числа кадров физического уровня на отдельном интервале эпизодической синхронизации от скважности импульсной помехи и начального положения помехи при:


- а) $\tau_p = (N_c + N_3)\tau$ («синхрогруппа»); б) $\tau_p = (N_c + N_3)\tau$ («заголовок»);
 в) $\tau_p = 0,125N_k\tau$; г) $\tau_p = 0,25N_k\tau$

Полученные зависимости показывают, что среднее число кадров физического уровня на отдельном интервале эпизодической синхронизации с высокой вероятностью превышает единицу только при скважности импульсной помехи $Q = 2$, а для других значений скважности в значительной мере зависит от длительности импульса помехи. Для используемых исходных данных число интервалов эпизодической синхронизации выше для нечетных значений скважности импульсной помехи. При этом повышение числа интервалов эпизодической синхронизации сопровождается уменьшением среднего числа кадров на отдельном интервале синхронизации. Среднее значение доли элементарных посылок,


подвергшихся воздействию помехи, не зависит от длительности импульса помехи и определяется только значением скважности.



а)



б)



в)

Рис. 4. Зависимости нормированного значения числа интервалов эпизодической синхронизации от скважности импульсной помехи при:

а) $\tau_p = (N_c + N_3) \tau$, б) $\tau_p = 0,125 N_k \tau$, в) $\tau_p = 0,25 N_k \tau$




Рис. 5. Зависимости нормированного значения среднего числа интервалов эпизодической синхронизации от свклажности импульсной помехи и начального положения помехи при: а) $\tau_p = (N_c + N_s)\tau$ («синхрогруппа»); б) $\tau_p = N_c + N_s\tau$ («заголовок»); в) $\tau_p = 0,125N_k\tau$ («синхрогруппа»); г) $\tau_p = 0,125N_k\tau$ («заголовок»); д) $\tau_p = 0,25N_k\tau$ («синхрогруппа»); е) $\tau_p = 0,25N_k\tau$ («заголовок»)




Рис. 6. Зависимости доли элементарных посылок, подвергшихся воздействию помехи на заданном интервале наблюдения от скважности импульсной помехи

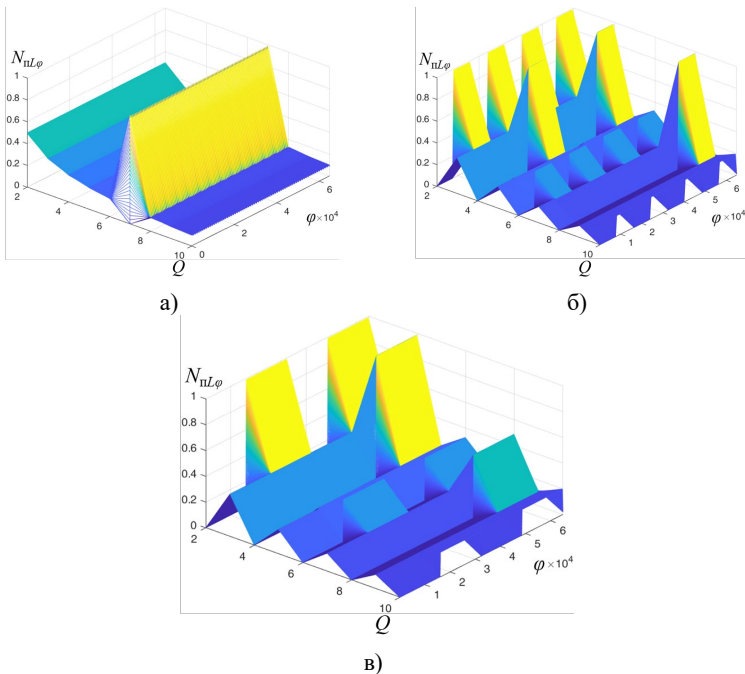


Рис. 7. Зависимости доли элементарных посылок, подвергшихся воздействию помехи на заданном интервале наблюдения от скважности импульсной помехи и начального положения помехи при: а) $\tau_p = (N_c + N_3)\tau$, б) $\tau_p = 0,125N_k\tau$, в) $\tau_p = 0,25N_k\tau$

Значения рассмотренных параметров эпизодической синхронизации в значительной мере зависят от начального положения (начальной фазы) помехи. С увеличением длительности импульса помехи интервалы значений φ , при которых возможно возникновение эффекта эпизодической синхронизации, расширяются, однако их число сокращается. Максимальные значения вероятности возникновения эффекта эпизодической синхронизации достигаются при значениях $Q = 2$ и $Q = 3$, однако для импульсов помех, имеющих длительность, равную длительности заголовка кадра, необходимо выделить значение $Q = 7$, при котором интервалы эпизодической синхронизации в зависимости от значения φ могут достигать максимальной длительности и максимального значения доли элементарных посылок в заголовке, подвергшихся воздействию помехи.

Теперь найдем вероятность потери кадра передаваемой информации при наличии собственных шумов приемника и непреднамеренных импульсных помех. Для этого рассмотрим модель функционирования канала спутниковой связи, структура которой представлена на рисунке 8.



Рис. 8. Структура модели функционирования канала спутниковой связи в условиях непреднамеренных импульсных помех

Будем считать, что кадр не принят корректно в случае наступления одного из следующих независимых событий:

- не обнаружена синхрогруппа и не выделены границы кадра, с вероятностью P_{oc} ;
- не корректно распознан заголовок кадра, с вероятностью $P_{оз}$;
- канальное кодирование, включающее помехоустойчивое кодирование и перемежение, не обеспечили исправление ошибок возникающих при приеме информационной части кадра с вероятностью $P_{ои}$.

Полагая, что нарушений связи не происходит, если прием ведется на фоне только канальных шумов и собственных шумов приемника системы спутниковой связи, сбой в приеме может происходить только при попадании импульсной помехи в соответствующую часть кадра. Тогда, без учета краевых эффектов, связанных с попаданием помехи на стык разных частей кадра, вероятность ошибочного приема кадра может быть определена выражениями:

$$P_{ок} = 1 - (1 - P_{oc})(1 - P_{оз})(1 - P_{ои}); \quad (5)$$

$$P_{oc} = P_{пс} P_{ошс}, \quad P_{оз} = P_{пз} P_{ошз}, \quad P_{ои} = P_{пи} P_{оши}, \quad (6)$$

где $P_{пс}$, $P_{пз}$, $P_{пи}$ – вероятности попадания импульсной помехи в синхрогруппу, в служебную часть заголовка кадра и в информационную часть кадра;

$P_{ошс}$, $P_{ошз}$, $P_{оши}$ – условные вероятности ошибок при приеме синхрогруппы, служебной части заголовка и информационной части кадра при условии воздействия импульсной помехи с учетом собственных шумов приемника и канальных шумов.

Полагая сдвиги импульсного потока помех и синхрогрупп кадра случайными и равновероятными, можно оценить вероятность попадания центра импульсной помехи в соответствующую часть кадра:

$$P_{пс} = P_{пк} N_c / N_k; \quad P_{пз} = P_{пк} N_z / N_k; \quad P_{пи} = P_{пк} N_i / N_k, \quad (7)$$

где $P_{пк}$ – вероятность попадания импульсной помехи в кадр:

$$P_{\text{пк}} = \begin{cases} N_{\kappa} \tau / T_p, & \text{при } T_p > N_{\kappa} \tau; \\ 1, & \text{при } T_p \leq N_{\kappa} \tau. \end{cases} \quad (8)$$

Определим условные вероятности нарушения работы приемника при обработке синхрогруппы, служебной части заголовка кадра и блока передаваемой информации при наличии импульсной помехи.

Обнаружение синхрогруппы ведется устройством, схема которого представлена на рисунке 9. Оно состоит из согласованного фильтра с одиночным импульсом (СФОИ), N_c линий задержки, умножителей, на входы которых подаются отсчеты с линий задержки и коэффициенты соответствующие символам синхрогруппы C_k , $k=1 \dots N_c$.




Рис. 9. Схема устройства обнаружения синхрогруппы

Для оценки условной вероятности ошибки $P_{\text{оис}}$ при приеме синхрогруппы и импульсной помехи рассмотрим выход сумматора в момент, когда первый символ синхрогруппы достигнет последнего отвода устройства обнаружения. Поскольку шумы и помехи некоррелированы с сигналом, на выходе сумматора появится сигнал, случайная составляющая которого будет обусловлена воздействием шума и помехи и постоянная составляющая, определяемая накоплением символов синхрогруппы с амплитудой равной $N_c w_m$, где w_m – постоянная составляющая на выходе СФОИ при условии наличия синхрогруппы на входе СФОИ. Поскольку коэффициенты C_k по модулю равны единице, то случайная составляющая на выходе сумматора в следствии центральной предельной теоремы будет иметь нормальное распределение с математическим ожиданием, равным нулю, и дисперсией равной:

$$\sigma^2 = N_c \sigma_{ш}^2 + N_{сн} \sigma_{п}^2, \quad (9)$$

где $\sigma_{ш}$ – среднеквадратическое отклонение амплитуды обусловленное шумом на выходе СФОИ, $\sigma_{п}$ – среднеквадратическое отклонение амплитуды, обусловленное воздействием помехи на выходе СФОИ.

При этом при отсутствии помехи отношение сигнал/шум по амплитуде на выходе СФОИ равно:

$$\frac{w_m}{\sigma_{ш}} = \sqrt{\frac{2E_s}{N_0}}, \quad (10)$$

где E_s – энергия одного символа синхрогруппы, N_0 – спектральная плотность мощности шума.

Поскольку сигнал при наличии помехи на выходе сумматора будет представлять собой случайную величину распределенную по нормальному закону с математическим ожиданием $N_c w_m$ и дисперсией σ , то вероятность ошибки при обнаружении синхрогруппы будет равна:

$$P_{ошс} = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{U_c} e^{-\frac{(x-N_c w_m)^2}{2\sigma^2}} dx, \quad (11)$$

где U_c – порог обнаружения синхрогруппы.

Используя замену $y = (x - N_c w_m) / \sigma$, выражение (11) можно представить в виде:

$$P_{ошс} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\frac{(U_c - N_c w_m)}{\sigma}} e^{-\frac{y^2}{2}} dy. \quad (12)$$

Перепишем выражение (12) с использованием интеграла вероятности $\Phi(x) = (1/\sqrt{2\pi}) \int_{-\infty}^x \exp(-y^2/2) dy$:

$$P_{ошс} = \Phi\left(\frac{(U_c - N_c w_m)}{\sigma}\right). \quad (13)$$

Подставляя (9) в (13) и произведя несложные алгебраические преобразования, получим:

$$P_{\text{ошс}} = \Phi \left(\frac{N_c w_m}{\sigma_{\text{ш}} \sqrt{N_c + N_{\text{сп}} \frac{\sigma_{\text{ш}}^2}{\sigma_{\text{ш}}^2}}} (u_c - 1) \right), \quad (14)$$

где $u_c = \frac{U_c}{N_c w_m}$ – нормированный порог обнаружения синхрогруппы.

Считая, что спектральная плотность мощности помехи D_0 равномерна в полосе полезного сигнала, то отношение дисперсий помеховой и шумовой составляющей равно отношению их спектральных плотностей $\sigma_{\text{ш}}^2 / \sigma_{\text{ш}}^2 = D_0 / N_0$. Учитывая вышеизложенное и подставляя (10) в (14) получим:

$$P_{\text{ошс}} = \Phi \left(\frac{\sqrt{\frac{2E_s}{N_0}} \frac{N_c}{\sqrt{N_c + N_{\text{сп}} \frac{D_0}{N_0}}} (u_c - 1) \right). \quad (15)$$

Проведя несложные алгебраические преобразования в итоге получим:

$$P_{\text{ошс}} = \Phi \left(\sqrt{\frac{2N_c E_s}{N_0 + N_{\text{сп}} D_0 / N_c}} (u_c - 1) \right). \quad (16)$$

В статье, в том числе, рассматривается случай использования адаптивных протоколов. Например, протоколы DVB-S2, DVB-S2(X), CCSDS-131b. В этих протоколах вместо кадров канального уровня используется понятие кадров физического уровня. Введение кадров физического уровня обусловлено тем фактом, что эти кадры и информация в их заголовочных частях используется для решения задач в том числе физического уровня, т.е. синхронизации и демодуляции. Кадр физического уровня имеет несколько вариантов служебной части заголовка. Каждый вариант служебной части

заголовка соответствует конкретной сигнально-кодовой конструкции, используемой в информационной части кадра. Собственно это необходимо для реализации механизма адаптации. Приемник при получении большого количества ошибок по обратному каналу посылает сообщение о необходимости перехода на более помехоустойчивые сигнально-кодовые конструкции. Однако, точной информации о том, когда поступит кадр с более помехоустойчивой сигнально-кодовой конструкцией и какая именно сигнально-кодовая конструкция будет использована на стороне приемника нет. Поэтому в заголовке кадра такого протокола помимо синхрогруппы, необходимой для обнаружения заголовка имеется служебная часть, содержащая информацию об используемой сигнально-кодовой конструкции.

Одним из вариантов обработки таких заголовков может быть несколько параллельных корреляторов. Количество корреляторов равно количеству вариантов служебных частей заголовков N_{M_3} или используемых вариантов сигнально-кодовой конструкции, каждый из которых осуществляет выделение своей служебной части. В этом случае для правильного приема служебной части заголовка необходимо чтобы коррелятор, обнаруживающий служебную часть передаваемого заголовка успешно его обнаружил, то есть выход коррелятора превысил порог. Выходы остальных $N_{M_3} - 1$ корреляторов, обнаруживающих другие виды служебных частей заголовков, не превысили порог обнаружения, то есть не произошло ложной тревоги. Для нахождения вероятности правильного приема служебной части заголовка $P_{ппз}$ необходимо найти многомерную плотность распределения вероятности. Однако, в первом приближении, можно полагать, что случайные величины на выходе корреляторов независимы, тогда вероятность правильного приема служебной части заголовка представим произведением вероятностей независимых событий:

$$P_{ппз} = P_{пз} P_{тн}^{N_{M_3}-1}, \quad (17)$$

где $P_{пз}$ – вероятность правильного приема заголовка коррелятором, настроенным на прием передаваемого заголовка, $P_{тн}$ – вероятность отсутствия ложной тревоги в корреляторах, настроенных на другие заголовки.

В процессе приема служебной части заголовка ошибка приема служебной части заголовка и ее правильный прием составляют

полную группу событий. Поэтому условная вероятность ошибки при приеме служебной части заголовка $P_{\text{ошз}}$ равна:

$$P_{\text{ошз}} = 1 - P_{\text{tp}} P_{\text{tn}}^{N_{M3}-1}. \quad (18)$$

Аналогично условной вероятности ошибки при приеме синхрогруппы, используя свойство $\Phi(x) = 1 - \Phi(-x)$, запишем:

$$P_{\text{tp}} = \Phi \left(\sqrt{\frac{2N_3 E_s}{N_0 + N_{\text{зп}} D_0 / N_3}} (1 - u_3) \right), \quad (19)$$

где $u_3 = \frac{U_3}{N_3 w_m}$ – нормированный порог обнаружения заголовка.

В свою очередь, сигнал на выходе корреляторов, настроенных на другие виды служебной части заголовка, будет представлять собой случайный процесс с нулевым математическим ожиданием и дисперсией σ , а вероятность отсутствия ложной тревоги будет равна:

$$P_{\text{tn}} = \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^{U_3} e^{-\frac{x^2}{\sigma^2}} dx = \Phi \left(\frac{U_3}{\sigma} \right) = \Phi \left(\sqrt{\frac{2N_3 E_s}{N_0 + N_{\text{зп}} D_0 / N_3}} u_3 \right). \quad (20)$$

Подставляя (19) и (20) в (18), получим:

$$P_{\text{ошз}} = 1 - \Phi \left(\sqrt{\frac{2N_3 E_s}{N_0 + N_{\text{зп}} D_0 / N_3}} (1 - u_3) \right) \Phi \left(\sqrt{\frac{2N_3 E_s}{N_0 + N_{\text{зп}} D_0 / N_3}} u_3 \right)^{N_{M3}-1}. \quad (21)$$

Необходимо отметить, что в формулах (16), (19), (21) учет времени воздействия помехи осуществляется за счет учета количества символов заголовка $N_{\text{зп}}$ или синхрогруппы $N_{\text{сп}}$, соответствующих времени воздействия помехи.

Для нахождения вероятности ошибки приема информационной части кадра необходимо рассмотреть реализуемые в семействе стандартов *DVB* средства канального кодирования.

В современных широкополосных системах связи семейства стандартов *DVB* часто используется сочетание легко декодируемых кодов Боуза-Чоудхури-Хоквингема (БЧХ) и турбоподобного (*turbo-like*) кодирования низкоплотностным помехоустойчивым

(*Low Density Parity Check – LDPC*) кодом вместе с блоковыми или псевдослучайными перемежителями. Операции кодирования и декодирования обеспечивают исправление независимых (случайных) ошибок на относительно коротких интервалах кода. При этом перемежение и восстановление обеспечивают разбиение группирующихся в пакеты ошибок на случайные ошибки. На практике в случае длинных *LDPC* кодов часто применяются псевдослучайные перемежители [15, 16].

Рассмотрим влияние перемежения. Пусть перемежитель (блоковый или псевдослучайный) имеет глубину перемежения M , то есть обеспечивает достаточно равномерное распределение M интервалов кода длиной N_i каждый по кадру длиной N_k . Для этого перемежитель должен иметь фактор рассеивания (*spreading factor*) (N_i, r) , то есть любые два элемента исходной последовательности, находящиеся на расстоянии друг от друга в пределах длительности кодового интервала, после перемежения оказываются на расстоянии не меньшем r элементов.

Без учета последствия помехи можно считать, что импульсная помеха длительностью τ_p приводит к росту вероятности ошибки при приеме последовательности из N_n символов, причем $N_n = \tau_p/\tau$.

При этом можно считать, что вся информационная часть кадра разделяется на две части: группу символов на фоне шума и помехи, имеющих одну вероятность ошибочного приема, и группу символов на фоне только шума, имеющих другую вероятность ошибочного приема. В условиях, когда длительность помехи пропорциональна длительности синхрогруппы или заголовка кадра, а также используется идеальный перемежитель (для которого $N_i = r = \sqrt{N_k}$), вероятность ошибочного приема кадра будет определяться только соотношением длительности помехи с глубиной перемежения M . Если глубина перемежения не превышает исправляющую способность помехоустойчивого кода $M \leq U_n$, то очевидно, что при длительности помехи меньше M вероятность ошибочного приема кадра на фоне помехи будет сходиться к вероятности ошибочного приема кадра на фоне шума, а при длительности помехи больше M – стремиться к единице.

Поэтому для оценки условной вероятности потери кадра при воздействии помехи на его информационную часть следует сначала оценить исправляющую способность кодов коррекции ошибок. Для оценок исправляющей способности кодов коррекции ошибок, при условии большой длины кодового слова целесообразно использовать

асимптотические границы. Поэтому для оценки исправляющей способности кодов коррекции ошибок воспользуемся асимптотической границей Варшавова-Гильберта [17]:

$$R(\delta) \geq 1 - h(\delta), \quad (22)$$

где R – скорость кодирования, $\delta = d/n$ – относительное кодовое расстояние, $h(\delta)$ – бинарная функция информационной энтропии [18]:

$$h(\delta) = -\delta \log_2 \delta - (1 - \delta) \log_2 (1 - \delta). \quad (23)$$

Полагая, что современные алгоритмы декодирования *LDPC* кодов обеспечивают производительность, близкую к границе Варшавова-Гильберта [19, 20], запишем максимальное количество ошибочных битов, которое может быть исправлено кодом коррекции ошибок U_n :

$$U_n = \left\lfloor \frac{nh^{-1}(1-R) - 1}{2} \right\rfloor, \quad (24)$$

где h^{-1} – функция, обратная бинарной информационной энтропии, которая может быть аппроксимирована как [21]:

$$h^{-1}(1-R) = \left(2^{0,6794(1-R)^{0,7244}} - 2^{-0,1357(1-R)^{2,8026}} \right)^{1,992}. \quad (25)$$

Теперь оценим вероятность того, что воздействие помехи во время приема информационной части кадра приведет к возникновению количества ошибочных битов N_n , превышающего U_n . Для этого рассмотрим пространство элементарных исходов приема информационной части кадра на фоне воздействия шумов и помехи, воздействовавшей, во время приема N_n битов. Графически такое пространство можно представить в виде таблицы изображенной на рисунке 10. Каждый элементарный исход такого «испытания», т.е. каждая ячейка таблицы соответствует количеству ошибок в информационной части кадра. При этом учитывается, что часть ошибок возникла во время приёма сигнала на фоне шума, а часть на фоне воздействия помехи и шума. Жирной линией обведено подмножество пространства элементарных исходов, которое

соответствует событию приема кадра с количеством ошибок, превышающем исправляющие возможности кода коррекции ошибок. Это и будет вероятность потери кадра при условии попадания помехи в информационную часть кадра $P_{\text{оши}}$. На рисунке P'_i – вероятность того, что в информационной части кадра, принятой во время отсутствия воздействия помехи возникнет i ошибок, P_j – вероятность того, что в информационной части кадра, принятой во время воздействия помехи возникнет j ошибок.

$P_{N_{\Pi}-N_{\Pi}}$	$N_{\Pi}-N_{\Pi}$	$N_{\Pi}-N_{\Pi}+1$...	$N_{\Pi}-N_{\Pi}+U_{\Pi}$	$N_{\Pi}-N_{\Pi}+U_{\Pi}+1$...	N_{Π}
...
$P_{U_{\Pi}+1}$	$U_{\Pi}+1$	$U_{\Pi}+2$...	$U_{\Pi}+U_{\Pi}+1$	$U_{\Pi}+U_{\Pi}+2$...	$N_{\Pi}+U_{\Pi}$
$P_{U_{\Pi}}$	U_{Π}	$U_{\Pi}+1$...	$U_{\Pi}+U_{\Pi}$	$U_{\Pi}+U_{\Pi}+1$...	$N_{\Pi}+U_{\Pi}-1$
...
P_1	1	2	...	$U_{\Pi}+1$	$U_{\Pi}+2$...	$N_{\Pi}+1$
P_0	0	1	...	U_{Π}	$U_{\Pi}+1$...	N_{Π}
	P_0	P_1	...	$P_{U_{\Pi}}$	$P_{U_{\Pi}+1}$...	$P_{N_{\Pi}}$

Рис. 10. Варианты количества ошибок, обусловленные воздействием шума и помехи

Суммируя все элементы пространства элементарных исходов, обведенные на рисунке 10 жирной линией получим вероятность ошибки во время приема информационной части кадра:

$$P_{\text{оши}} = 1 - \sum_{i=0}^{\min(U_{\Pi}, N_{\Pi}-N_{\Pi})} \sum_{j=0}^{\min(U_{\Pi}-i, N_{\Pi})} P'_i P_j . \quad (26)$$

Считая воздействующую помеху на интервале ее существования стационарной, а вероятности ошибки при приеме каждого канального бита независимыми событиями положим, что вероятности P'_i и P_j распределены по биномиальному закону:

$$P'_i = C_{N_{\Pi}-N_{\Pi}}^i p_{\text{ber}}^{\text{ш } i} (1-p_{\text{ber}}^{\text{ш}})^{N_{\Pi}-N_{\Pi}-i} , \quad (27)$$

$$P_j = C_{N_{\Pi}}^j p_{\text{ber}}^{\text{п } j} (1-p_{\text{ber}}^{\text{п}})^{N_{\Pi}-j} , \quad (28)$$

где p_{ber}^{III} , p_{ber}^{II} – вероятности битовой ошибки при приеме информационной части кадра на фоне шума и на фоне помехи и шума соответственно.

В семействе стандартов *DVB* реализовано четыре основных режима модуляции: *QPSK* и *8PSK*, являющиеся основными, и *16APSK* и *32APSK*, используемые при высоком уровне сигнал/шум.

Рассматривая *QPSK* в качестве основного режима модуляции, определим p_{ber}^{III} и p_{ber}^{II} с учетом того, что помеха представляет собой импульсы шума [22]:

$$p_{ber}^{II} = \Phi \left(\sqrt{\frac{2E_b}{D_0}} \right), \quad (29)$$

$$p_{ber}^{III} = \Phi \left(\sqrt{\frac{2E_b}{N_0}} \right). \quad (30)$$

Например, для $E_b/N_0 = 16,5$ дБ $p_{ber}^{III} = 10^{-6}$, и зависимость $p_{ber}^{II}(E_b/N_0)$ приведена на рисунке 11.




Рис. 11. Зависимость вероятности битовой ошибки при приеме информационной части кадра от отношения сигнал/помеха при фиксированном отношении сигнал/шум

В качестве примера рассмотрим воздействие импульсных помех на кадр, передаваемый в канале связи стандарта *DVB-S2*, когда уже возникли условия эпизодической синхронизации потока кадров с потоком импульсных помех.

3. Результаты аналитической оценки влияния импульсных помех на прием информации в спутниковом канале связи стандарта *DVB-S2* в условиях эпизодической синхронизации с потоком импульсных помех. Параметры заголовков и длительность информационной части кадров для указанного стандарта описаны в работах [10, 15, 16]. В качестве основного режима модуляции выберем *QPSK*.

Полученные выше значения p_{ber}^{III} и p_{ber}^I позволяют рассчитать вероятность ошибки во время приема синхрогруппы, служебной части заголовка кадра и информационной части кадра, а также вероятность ошибочного приема кадра (рисунки 12, 13, 14 и 15 соответственно). При этом рисунки 12(а), 13(а), 14(а) и 15(а) представляют собой зависимости вероятности ошибки приема соответствующей части кадра от отношения сигнал/помеха при фиксированном отношении сигнал/шум для различных значений длительности импульса помехи, а рисунки 12(б), 13(б), 14(б) – зависимости вероятности ошибки приема соответствующей части кадра от длительности импульса помехи при фиксированных отношениях сигнал/помеха. Вычисления производились в соответствии с выражениями (16), (21), (26) и (5) соответственно. При изменении скважности периодической последовательности импульсов шума была зафиксирована средняя мощность.

На рисунке 12(а) представлено семейство зависимостей вероятности ошибки во время приема синхрогруппы от отношения сигнал/помеха при фиксированном отношении сигнал/шум. Полученные зависимости показывают, что с увеличением длительности импульса помехи отношение сигнал/помеха, при котором обеспечивается заданный уровень вероятности ошибки, уменьшается. Это обусловлено снижением доли энергии помехи, приходящейся на синхрогруппу. При этом при низких отношениях сигнал/помеха вероятность ошибки при приеме синхрогруппы остается относительно высокой при любых длительностях импульса помехи, как показано на рисунке 12(б).




Рис. 12. Зависимость вероятности ошибки во время приема синхрогруппы от:
 а) отношения сигнал/помеха при фиксированном отношении сигнал/шум;
 б) от длительности импульса помехи

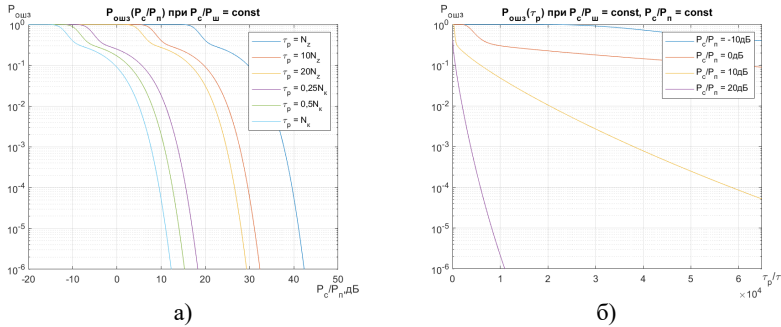


Рис. 13. Зависимость вероятности ошибки во время приема заголовка кадра от:
 а) отношения сигнал/помеха при фиксированном отношении сигнал/шум;
 б) от длительности импульса помехи

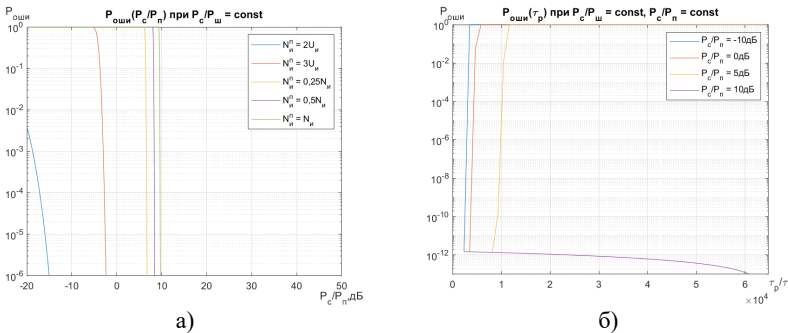


Рис. 14. Зависимость вероятности ошибки во время приема информационной части кадра от:
 а) отношения сигнал/помеха при фиксированном отношении сигнал/шум;
 б) от длительности импульса помехи




Рис. 15. Зависимость вероятности ошибочного приема кадра от:
 а) длительности импульса помехи; б) от отношения сигнал/помеха при фиксированном отношении сигнал/шум и от длительности импульса помехи

Для служебной части заголовка кадра вероятность ошибочного приема уменьшается с увеличением длительности импульса помехи аналогично синхрогруппе (рисунок 13(а)), однако при низких отношениях сигнал/помеха и малой длительности импульса помехи можно наблюдать более высокую скорость убывания функции вероятности ошибочного приема служебной части заголовка кадра (рисунок 13(а, б)). Данное обстоятельство обусловлено применением многоканального коррелятора при приеме служебной части заголовка кадра.

Вероятность ошибочного приема информационной части кадра, в целом, носит пороговый характер, определяемый исправляющей способностью помехоустойчивого кодирования, и слабо зависит от длительности импульса помехи. При этом при высоком отношении сигнал/помеха вероятность ошибочного приема информационной части кадра стремится к вероятности ошибочного приема данной части кадра в условиях воздействия только шумов, как показано на рисунке 14(б).

Из зависимостей, представленных на рисунке 15(а) следует, что при низких отношениях сигнал/помеха вероятность потери кадра при воздействии коротких импульсных помех определяется, в основном, вероятностью ошибочного приема заголовка, а при воздействии импульсов помех большой длительности – только вероятностью ошибочного приема информационной части кадра. Однако при высоких отношениях сигнал/помеха вероятность потери информационной части кадра не оказывает существенного влияния на общую вероятность потери кадра. В таком случае вероятность потери кадра определяется, в основном, условными вероятностями ошибки

при приеме синхрогруппы и ошибочного приема служебной части заголовка кадра. Это доказывает тот факт, что именно воздействие коротких импульсов помех на служебную часть кадра может приводить к более высокой вероятности потери кадра.

Соответственно, на рисунке 15(б) область 1 (выделенная синим цветом), определяет диапазоны значений отношений сигнал/помеха и длительностей импульса помехи, при которых основной вклад в вероятность ошибочного приема кадра вносит вероятность ошибки при приеме информационной части кадра. Область 2 (выделенная красным цветом), определяет соответствующие диапазоны, при которых основной вклад в вероятность ошибочного приема кадра вносит вероятность ошибки при приеме заголовка кадра.

4. Заключение. В статье представлена аналитическая оценка влияния импульсных помех на прием информации в спутниковом канале связи в условиях эпизодической синхронизации кадров физического уровня канала спутниковой связи с потоками импульсных помех.

Результаты аналитической оценки вероятности ошибочного приема кадра стандарта DVB-S2 показывают, что при низких отношениях сигнал/помеха (не более 3 дБ) вероятность потери кадра при воздействии коротких импульсных помех, длительность которых не превышает 5% длительности кадра, определяется, в основном, вероятностью ошибочного приема заголовка, а при воздействии импульсов помех большой длительности – только вероятностью ошибочного приема информационной части кадра. При высоких отношениях сигнал/помеха (превышающих 3-5 дБ) вероятность потери информационной части кадра не оказывает существенного влияния на общую вероятность потери кадра, определяемую, в основном, условными вероятностями ошибки при приеме синхрогруппы и ошибочного приема служебной части заголовка кадра. При этом существенное значение имеет длительность импульса помехи.

При приеме синхрогруппы с увеличением длительности импульса помехи отношение сигнал/помеха, при котором обеспечивается заданный уровень вероятности ошибки, уменьшается. Это обусловлено снижением доли энергии помехи, приходящейся на синхрогруппу.

Для служебной части заголовка кадра вероятность ошибочного приема уменьшается с увеличением длительности импульса помехи аналогично синхрогруппе, однако применение многоканального коррелятора при низких отношениях сигнал/помеха и малой

длительности импульса помехи приводит к более высокой скорости убывания функции вероятности ошибочного приема служебной части заголовка кадра.

Вероятность ошибочного приема информационной части кадра, в целом, носит пороговый характер, определяемый исправляющей способностью помехоустойчивого кодирования и соотношением длительности импульса помехи с интервалом перемежения.

Таким образом, доказано, что существуют такие соотношения длительности импульса шумовой помехи с длительностью служебных частей кадра физического уровня канала спутниковой связи, при которых воздействие импульсной помехи на служебную часть кадра может приводить к более высокой вероятности ошибочного приема кадра, чем при воздействии на информационную часть кадра. Это происходит при сочетании двух условий: длительность помехи соизмерима с длительностью заголовка кадра или в несколько раз больше, и не обеспечивается достаточное превышение мощности сигнала над средней мощностью помехи.

Литература

1. Зюко А.Г., Кловский Д.Д., Коржик В.И., Назаров М.В. Теория электрической связи. М.: Радио и связь. 1999. 432 с.
2. Борисов В.И., Зинчук В.М., Лимарев А.Е. Помехозащищенность систем радиосвязи с расширением спектра сигналов модуляцией несущей псевдослучайной последовательностью. М.: Радио и связь. 2003. 640 с.
3. Калинин В.С., Белов С.П. Обзор источников помех в спутниковых системах связи // Научный результат. Информационные технологии. 2022. Т. 7. № 3. С. 3–13.
4. Тяпкин П.С., Важенин Н.А. Повышение помехоустойчивости систем связи в условиях импульсных квазигармонических помех с использованием слепых методов обработки сигналов // Труды МАИ. 2023. № 128. DOI: 10.34759/trd-2023-128-13.
5. Puzko D., Batov Y., Gelgor A., Tkachenko D., Angueira P., Montalban J. Evaluation of Finite Discrete RRC-Pulse Parameters to Simulate DVB-S2 with LDM // IEEE International Conference on Electrical Engineering and Photonics (EExPolytech). 2019. pp. 140–143.
6. Oh H., Nam H. Maximum Rate Scheduling With Adaptive Modulation in Mixed Impulsive Noise and Additive White Gaussian Noise Environments // IEEE Transactions on Wireless Communications. 2021. vol. 20. no. 5. pp. 3308–3320.
7. He Y., Zou, Li D., Yao R., Yang F., Song J. Adaptive Impulsive Noise Suppression: A Deep Learning-Based Parameters Estimation Approach // IEEE Transactions on Broadcasting. 2023. vol. 69. no. 2. pp. 505–515. DOI: 10.1109/TBC.2022.3224249.
8. Bejarano J.M.R., Miguel N.C., Ruiz Pinar F.J. MF-TDMA Scheduling Algorithm for Multi-Spot Beam Satellite Systems Based on Co-Channel Interference Evaluation // IEEE Access. 2018. vol. 7. pp. 4391–4399.
9. Паршуткин А.В., Маслаков П.А. Исследование помехоустойчивости современных стандартов спутниковой связи к воздействию нестационарных помех. Труды СПИИРАН. 2017. № 4(53). С. 159–177.

10. Паршуткин А.В., Бучинский Д.И. Модель функционирования канала спутниковой связи в условиях искажений служебной части кадров нестационарными помехами. Информатика и автоматизация. 2020. Т. 19. № 5. С. 967–990.
11. Агневич С.Н., Борисов В.В., Дворников С.В., Луценко С.А. Предложения по оценке эффективности преднамеренных помех элементам синхронизации сигналов спутниковых систем // Вопросы оборонной техники. Серия 16: Технические средства противодействия терроризму. 2019. № 5–6. С. 114–120.
12. Луценко С.А. Подход к расчету энергетического выигрыша при постановке помех системе цикловой синхронизации спутниковых линий связи // Журнал радиоэлектроники. 2019. № 3. DOI: 10.30898/1684-1719.2019.3.14.
13. Бучинский Д.И., Паршуткин А.В. Модель воздействия нестационарных помех на кадровую синхронизацию спутниковой системы связи // Труды Военно-космической академии имени А.Ф. Можайского. 2019. № 671. С. 114–119.
14. Sormunen L., Puttonen J., Kurjenniemi J. System Level Modelling of DVB-S2X in High Throughput Satellite System // 36th International Communications Satellite Systems Conference (ICSSC 2018). 2018. pp. 1–4. DOI: 10.1049/cp.2018.1709.
15. ETSI EN 302 307 V1.2.1 Digital Video Broadcasting (DVB); Second Generation Framing Structure, Channel Coding and Modulation Systems for Broadcasting, Interactive Services, News Gathering and Other Broadband Satellite Applications. Part 2: DVB-S2 Extensions (DVB-S2X). 2020-02.
16. ETSI EN 301 545-2 V1.1.1 Digital Video Broadcasting (DVB); Second Generation DVB Interactive Satellite System (DVB-RCS2); Part 2: Lower Layers for Satellite Standard. 2012-01. 195 p. Available at: https://www.etsi.org/deliver/etsi_en/301500_301599/30154502/01.01.01_60/en_30154502v010101p.pdf (accessed 20.10.2023).
17. Касами Т., Токура Н., Ивадари Ё., Инагаки Я. Теория кодирования: Пер. с японского. М.: Мир, 1978. 576 с.
18. Madiman M., Marcus A., Tetali P. E Entropy and Set Cardinality Inequalities for Partition-Determined Functions and Application to Sumsets // Random Structures and Algorithms. 2012. pp. 399–424.
19. Gaborit P., Zemor G. Asymptotic improvement of the Gilbert-Varshamov bound for binary linear codes. IEEE Transactions on Information Theory. 2008. vol. 54. no. 9. pp. 3865–3872.
20. Hao H., Chen J., Zhou Y. An Irregular Row Weight Problem Resolution for DVB-S2 LDPC Short Frame // 7th IEEE International Conference on Electronics Information and Emergency Communication (ICEIEC). 2017. pp. 45–48.
21. Zhou X., Cheng M., He X., Matsumoto T. Exact and Approximated Outage Probability Analyses for Decode-and-Forward Relaying System Allowing Intra-Link Errors. IEEE Transactions on Wireless Communications. 2014. vol. 13. no. 12. pp. 7062–7071. DOI: 10.1109/TWC.2014.2354337.
22. Lee P. Computation of the Bit Error Rate of Coherent M-ary PSK with Gray Code Bit Mapping. IEEE Transactions on Wireless Communications. 1986. vol. 34. no. 5. pp. 488–491.

Паршуткин Андрей Викторович — д-р техн. наук, профессор, доцент, кафедра систем и средств радиоэлектронной борьбы, Военно-космическая академия имени А.Ф. Можайского (ВКА им. А.Ф. Можайского). Область научных интересов: радиоэлектронная защита радиоэлектронных средств и систем, методы оценивания результативности помех и радиоэлектронных воздействий, методы создания интеллектуальных помех и защиты от них, методы и средства технической защиты информации. Число научных публикаций — 120. andydc2010@mail.ru; улица Ждановская, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(812)347-9535.

Бучинский Дмитрий Игоревич — канд. техн. наук, преподаватель, кафедра систем и средств радиоэлектронной борьбы, Военно-космическая академия имени А.Ф. Можайского (ВКА им. А.Ф. Можайского). Область научных интересов: радиоэлектронная защита радиоэлектронных средств и систем, методы создания интеллектуальных помех, помехоустойчивость систем спутниковой связи. Число научных публикаций — 7. reys-rd@ya.ru; улица Ждановская, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(926)015-8274.

Копалов Юрий Николаевич — адъюнкт, Военно-космическая академия имени А.Ф. Можайского (ВКА им. А.Ф. Можайского). Область научных интересов: радиоэлектронная защита радиоэлектронных средств и систем, методы создания интеллектуальных помех, помехоустойчивость систем спутниковой связи. Число научных публикаций — 6. yury.kopalov.s@mail.ru; улица Ждановская, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(999)200-1804.

A.V. PARSHUTKIN, D.I. BUCHINSKIY, YU.N. KOPALOV
**MODEL OF SATELLITE COMMUNICATION CHANNEL
FUNCTIONING UNDER CONDITIONS OF EPISODIC
SYNCHRONIZATION WITH PULSE INTERFERENCE FLOWS**

Parshutkin A.V., Buchinskiy D.I., Kopalov Yu.N. Model of Satellite Communication Channel Functioning under Conditions of Episodic Synchronization with Pulse Interference Flows.

Abstract. The article investigates the effect of pulse interference on information reception in conditions of episodic synchronization of frames of the physical level of a satellite communication channel with streams of radio pulses of unintended interference. An analytical model of the influence of pulse interference on the reception of information in a satellite communication channel under conditions of episodic synchronization of physical-level frames with pulse interference streams is proposed. Using the example of the DVB family of standards, the combined effect of noise and unintended impulse interference on the conditional error probabilities when receiving a synchro group, the service part of the header and the information part of the frame is shown. Estimates of the average number of frames of the physical level for the duration of the interval of episodic synchronization, the number of intervals of episodic synchronization and the proportion of elementary parcels in the frame exposed to interference, depending on the duration of the pulse interference, are given. It is shown that there are such relations between the duration of the interference pulse and the continuity of the sequence, in which the phenomenon of the episodic synchronization of physical-level frames with the flow of pulse interference has a significant impact on the functioning of the satellite communication channel. The dependences of the probability of erroneous reception of a frame of the physical level of a satellite communication channel on the signal-to-interference ratio at the fixed signal-to-noise ratio and on the duration of the interference pulse are obtained. It has been found that at high signal-to-noise ratios and the duration of the interference correlated with the duration of the service part of the frame, but significantly less than the duration of the frame, the probability of erroneous reception of the frame may be higher than at lower signal-to-noise ratios due to errors when receiving the service part of the frames.

Keywords: episodic synchronization, unintentional pulse interference, DVB, noise immunity, broadband satellite communication.

References

1. Zyuko A.G., Klovsij D.D., Korzhik V.I., Nazarov M.V. *Teoriya elektricheskoy svyazi [Theory of Electrical Communication]*. M.: Radio I svyaz. 1999. 432 p. (In Russ.).
2. Pomexozashhishhenost system radiosvyazi s rasshireniem spectra signalov modulyaciej nesushhej psevdosluchajnoj posledovatelnostyu [Noise Immunity of Radio Communication Systems with the Expansion of the Signal Spectrum by Carrier Modulation Pseudorandom Sequence]. M.: Radio I svyaz. 2003. 640 p. (In Russ.).
3. Kalinin V.C., Belov C.P. [Overview of Interference Sources in Satellite Communication Systems]. Scientific result. Information Technology – Nauchnyj rezultat. Informaciiionnye tekhnologii. 2022. vol. 7. no. 3. pp. 3–13. (In Russ.).
4. Tyapkin P.C., Vazhenin N.A. [Improving the Noise Immunity of Communication Systems in Conditions of Pulsed Quasiharmonic Interference Using Blind Signal Processing Methods].

5. Proceedings of MAI – Trudy MAI. 2023. no. 128. DOI: 10.34759/trd-2023-128-13. (In Russ.).
6. Puzko D., Batov Y., Gelgor A., Tkachenko D., Angueira P., Montalban J. Evaluation of Finite Discrete RRC-Pulse Parameters to Simulate DVB-S2 with LDM. IEEE International Conference on Electrical Engineering and Photonics (EEEPolytech). 2019. pp. 140–143.
7. Oh H., Nam H. Maximum Rate Scheduling With Adaptive Modulation in Mixed Impulsive Noise and Additive White Gaussian Noise Environments. IEEE Transactions on Wireless Communications. 2021. vol. 20. no. 5. pp. 3308–3320.
8. He Y., Zou, Li D., Yao R., Yang F., Song J. Adaptive Impulsive Noise Suppression: A Deep Learning-Based Parameters Estimation Approach. IEEE Transactions on Broadcasting. 2023. vol. 69. no. 2. pp. 505–515. DOI: 10.1109/TBC.2022.3224249.
9. Bejarano J.M.R., Miguel N.C., Ruiz Pinar F.J. MF-TDMA Scheduling Algorithm for Multi-Spot Beam Satellite Systems Based on Co-Channel Interference Evaluation // IEEE Access. 2018. vol. 7. pp. 4391–4399.
10. Parshutkin A.V., Maslakov P.A. [Study of the Noise Immunity of Modern Standards of Satellite Communications to the Impact of Non-Stationary Interference]. Informatika i avtomatizaciya – Informatics and Automation. 2017. no. 4(53). pp. 159–177. (In Russ.).
11. Parshutkin A.V., Buchinskiy D.I. [Model of Satellite Communication Channel Functioning under Conditions of Disturbances of Service Part of Frames by Unsteady Interference]. Trudy SPIIRAN – SPIIRAS Proceedings. 2020. vol. 19. no. 5. pp. 967–990. (In Russ.).
12. Agievich S.N., Borisov V.V., Dvornikov S.V., Lucenko S.A. [Proposals for Evaluating the Effectiveness of Intentional Interference to Synchronization Elements of Satellite Systems]. Voprosy oboronnoj tekhniki.0 Seriya 16: Tehnicheskie sredstva protivodejstvija terrorizmu – Military Enginery. Episode 16: Technical means of Mixed countering terrorism. 2019. no. 5–6. pp. 114–120. (In Russ.).
13. Lucenko S.A. [Approach to Calculating the Energy Gain when Jamming the System of Cyclic Synchronization of Satellite Communication Lines]. Zhurnal radioelektroniki – Journal of Radio Electronics. 2019. no. 3. DOI: 10.30898/1684-1719.2019.3.14. (In Russ.).
14. Parshutkin A.V., Buchinskiy D.I. [A Model of the Impact of Non-stationary Interference on the Frame Synchronization of a Satellite Communication System]. Trudy Voenno-kosmicheskoy akademii im. A.F.Mozhajsikogo – Proceedings of the Mozhaisky Military Space Academy. 2019. № 671. С. 114–119. (In Russ.).
15. Sormunen L., Puttonen J., Kurjenniemi J. System Level Modelling of DVB-S2X in High Throughput Satellite System. 36th International Communications Satellite Systems Conference (ICSSC 2018). 2018. pp. 1–4. DOI: 10.1049/cp.2018.1709.
16. ETSI EN 302 307 V1.2.1 Digital Video Broadcasting (DVB); Second Generation Framing Structure, Channel Coding and Modulation Systems for Broadcasting, Interactive Services, News Gathering and Other Broadband Satellite Applications. Part 2: DVB-S2 Extensions (DVB-S2X). 2020-02.
17. ETSI EN 301 545-2 V1.1.1 Digital Video Broadcasting (DVB); Second Generation DVB Interactive Satellite System (DVB-RCS2); Part 2: Lower Layers for Satellite Standard. 2012-01. 195 p. Available at: https://www.etsi.org/deliver/etsi_en/301500_301599/30154502/01.01.01_60/en_30154502v010101p.pdf (accessed 20.10.2023).
18. Vu V., Wu L. Improving the Gilbert-Varshamov Bound for Q-ary Codes // IEEE Transactions on Information Theory. 2005. vol. 51. no. 9. pp. 3200–3208.

19. Madiman M., Marcus A., Tetali P. E Entropy and Set Cardinality Inequalities for Partition-Determined Functions and Application to Sumssets. *Random Structures and Algorithms*. 2012. pp. 399–424.
20. Gaborit P., Zemor G. Asymptotic improvement of the Gilbert-Varshamov bound for binary linear codes. *IEEE Transactions on Information Theory*. 2008. vol. 54. no. 9. pp. 3865–3872.
21. Hao H., Chen J., Zhou Y. An Irregular Row Weight Problem Resolution for DVB-S2 LDPC Short Frame. 7th IEEE International Conference on Electronics Information and Emergency Communication (ICEIEC). 2017. pp. 45–48.
22. Zhou X., Cheng M., He X., Matsumoto T. Exact and Approximated Outage Probability Analyses for Decode-and-Forward Relaying System Allowing Intra-Link Errors. *IEEE Transactions on Wireless Communications*. 2014. vol. 13. no. 12. pp. 7062–7071. DOI: 10.1109/TWC.2014.2354337.
23. Lee P. Computation of the Bit Error Rate of Coherent M-ary PSK with Gray Code Bit Mapping. *IEEE Transactions on Wireless Communications*. 1986. vol. 34. no. 5. pp. 488–491.

Parshutkin Andrey — Ph.D., Dr.Sci., Professor, Associate professor, Department of electronic warfare systems, Mozhaisky Military Space Academy. Research interests: electronic protection of electronic equipment and systems, methods of estimating the impact of noise and electronic influences, methods of creation of intellectual interference and protection, methods and means of technical protection of information. The number of publications — 120. andydc2010@mail.ru; 13, Zhdanovskaya St., 197198, St. Petersburg, Russia; office phone: +7(812)347-9535.

Buchinskiy Dmitriy — Ph.D., Lecturer, Department of electronic warfare systems, Mozhaisky Military Space Academy. Research interests: electronic protection of electronic equipment and systems, methods of estimating the impact of noise and electronic influences, methods of creation of intellectual interference and protection, immunity of satellite communication systems. The number of publications — 7. reys-rd@ya.ru; 13, Zhdanovskaya St., 197198, St. Petersburg, Russia; office phone: +7(926)015-8274.

Kopalov Yury — Student, Mozhaisky Military Space Academy. Research interests: electronic protection of electronic equipment and systems, methods of estimating the impact of noise and electronic influences, methods of creation of intellectual interference and protection, immunity of satellite communication systems. The number of publications — 6. yury.kopalov.s@mail.ru; 13, Zhdanovskaya St., 197198, St. Petersburg, Russia; office phone: +7(999)200-1804.

О.М. ЛЕПЕШКИН, О.А. ОСТРОУМОВ, Н.В. МИХАЙЛИЧЕНКО,
А.С. ПЕРМЯКОВ

**МЕТОДИКА ОБЕСПЕЧЕНИЯ ФУНКЦИОНАЛЬНОЙ
УСТОЙЧИВОСТИ СИСТЕМЫ СВЯЗИ ЗА СЧЕТ ВЫЯВЛЕНИЯ
КОНФЛИКТОВ**

Лепешкин О.М., Остроумов О.А., Михайличенко Н.В., Пермяков А.С. Методика обеспечения функциональной устойчивости системы связи за счет выявления конфликтов.

Аннотация. Введение: Современные сложные технические системы часто бывают критически важными. Критичность обусловлена последствиями нарушения функционирования таких систем, не выполнением ими требуемого перечня функций и задач. Процесс контроля и управления такими системами осуществляется с использованием систем и сетей связи, которые становятся для них критичными. Возникает потребность в обеспечении устойчивого функционирования, как самих сложных технических систем, так и их систем управления, контроля, систем и сетей связи. В работе предложена методика обеспечения функциональной устойчивости системы связи, основой которой является процесс выявления и устранения в ней конфликтов, обусловленных отличием профиля функционирования и профиля процесса функционирования системы. Предложенная модель процесса функционирования системы связи позволяет на основе анализа интенсивностей воздействия дестабилизирующих факторов на систему, выявления конфликтов и их устранения, определить вероятность обеспечения функциональной устойчивости системы. Цель исследования: разработка методики обеспечения функциональной устойчивости системы связи в условиях воздействия дестабилизирующих факторов и возникновения конфликтов, а также модели процесса функционирования системы связи, позволяющей определять вероятность нахождения системы в функционально устойчивом состоянии. Методы теории графов и теории матриц, теории Марковских процессов. Результаты: предложена модель процесса функционирования системы связи в условиях воздействия дестабилизирующих факторов, позволяющая определять вероятность нарушения функционирования системы, разработана методика обеспечения функциональной устойчивости системы связи. Практическая значимость: результаты исследования могут быть использованы при проектировании и построении сложных технических систем, а также в системах поддержки принятия решений, контроля, связи и управления.

Ключевые слова: функциональная устойчивость, критичность, система связи, система управления, сложная техническая система, профиль функционирования системы, функции, задачи, регламент.

1. Введение. Современные системы управления имеют в своем составе системы или сети связи. Значение связи в условиях повсеместной цифровизации и использования информационных технологий значительно возрастает. Системы связи (СС) приобретают важное критическое значение для систем управления (СУ), при этом критичность проявляется в последствиях нарушений функционирования систем, в их неспособности выполнять определенные требуемые задачи и функции. Усложнение системы, увеличение ее возможностей, большая

динамика изменения состояний системы и ее элементов определяют потребность в информации о ее состоянии, а также происходящих в ней процессах. Информация о состоянии СС позволит СУ своевременно влиять на нее для обеспечения ее устойчивого функционирования.

В процессе функционирования на систему, которая выполняет определенный набор функций и задач, воздействуют различные дестабилизирующие факторы (ДФ) [1, 2]. Под ДФ будет пониматься любое воздействие на СС и ее элементы, результатом которого является нарушение ее функционирования.

Под функциональной устойчивостью (ФУ) СС понимается ее способность обеспечивать выполнение функций и задач в условиях воздействия на нее различных ДФ [3, 4].

В работе при оценке ФУ не учитывается осведомленность злоумышленника, уровень его подготовки, квалификация и техническое оснащение, а также характер воздействия и факторы, влияющие на систему [5, 6]. Учитывается только воздействие на СС, результатом которого является нарушение устойчивого функционирования СС и ее элементов, т.е. невыполнение системой функций и задач, профиля функционирования системы [7].

Традиционно устойчивость системы связи рассматривается через надежность [8 – 12], живучесть [13, 14], помехоустойчивость [15, 16] и киберустойчивость [17 – 22], при этом в качестве характеристики устойчивости, как правило, выступает только один параметр. Реже устойчивость рассматривается как свертка показателей перечисленных характеристик. Кроме этого, ряд работ посвящен общесистемным вопросам обеспечения устойчивости сложных технических систем [23 – 26]. Оценка показателей устойчивости осуществляется на основании анализа статистики функционирования СС до момента оценки, что в условиях большой динамики изменения обстановки, а также потребности в получении информации о системе в режиме реального времени, не всегда приемлемо.

В иностранных источниках термины функциональная устойчивость, функциональная надежность и функциональная живучесть используются наравне. Вклад в развитие теории функциональной устойчивости внесли Додонов А.Г., Тарасов А.А., Бородакий Ю.В. [4, 27], Богатырев В.А., Богатырев А.В. [28 – 29], Турута Е.Н. [30 – 31], Кривошея Д.О., Васильев С.В., Демчук В.А., Двилянский А.А., Машков О.А. [32], Королев А.Н. [33], Фирсов С.Н., Климов С.М., Одоевский С.М. и др. В работах этих авторов под функциональной устойчивостью, как правило, понимается функциональная надежность систем и объектов, обеспечение которой

связано только со структурной реконфигурацией системы, объекта. Отличительной особенностью разработанной авторами методики, является предложение на осуществление синтеза не только структуры системы, но и ее функциональной характеристики, определяемой целевым предназначением системы. Кроме того, авторами предложен новый подход формализации системы на основе профиля функционирования системы, а также процесса ее функционирования на основе профиля процесса функционирования системы. В рамках методики разработана новая модель процесса функционирования СС, позволяющая определить вероятность нарушения устойчивого функционирования системы в зависимости от интенсивности воздействия ДФ, интенсивность синтеза системы, влияющего на время ее устойчивого функционирования.

Разработанная методика обеспечения функциональной устойчивости СС в условиях воздействия на нее и ее элементы дестабилизирующих факторов предназначена для должностных лиц, занимающихся планированием связи, а также лиц, которые принимают решение в этой системе. Время, необходимое для синтеза системы, определяет интервал проверки готовности к выполнению текущей задачи, функции.

Синтез СС будет представлять собой функциональный синтез, заключающийся в перераспределении ресурсов для выполнения задач и задач для выполнения функций, а также структурный синтез системы, включающий реконфигурацию физической основы СС.

Цель работы заключается в разработке методики обеспечения ФУ СС, позволяющей в условиях воздействия ДФ и изменения состояний системы, обстановки, выявлять конфликты в ней, обусловленные отличием профиля процесса функционирования системы от профиля функционирования системы в любой момент времени. На основании полученных данных принимать меры для синтеза, как структуры системы, так и ее функциональной характеристики.

Научная новизна полученных результатов заключается в разработке новой методики обеспечения ФУ СС, использующей профиль функционирования системы для выявления конфликтов, обусловленных воздействием на систему различных ДФ. Кроме этого, получена новая модель процесса функционирования СС на основе использовании математического аппарата теории Марковских процессов, которая позволяет оценивать время и вероятность сохранения требуемой ФУ СС.

3. Постановка задачи на исследование. Своевременное обнаружение конфликта в системе связи и правильное реагирование на

него до момента окончания выполнения задачи, функции путем синтеза системы позволит выполнить задачу, функцию и обеспечить ФУ СС, независимо от характера воздействия ДФ.

Оптимизационная задача заключается в поиске такого решения выявления конфликта, при устранении которого требуется задействование минимального ресурса системы, использование которого позволит обеспечить достижение целевого предназначения системы и обеспечить ее ФУ.

Целевую функцию можно представить следующим выражением:

$$\langle W(\vec{E}, j), F \rangle \rightarrow \min \Delta E \mid k_{\text{ФУ}} \leq k_{\text{ФУ треб}}, j \in N, \quad (1)$$

где $W(\vec{E}, j)$ – упорядоченное множество векторов ресурсов СС, обеспечивающих ее функционирование и выполнение целевого предназначения; $j \in N$ – количество элементов СС, характеризующих структуру системы связи; F – интенсивность вариации элементов СС, позволяющих предоставлять системе связи требуемый ресурс; $k_{\text{ФУ}}$ – коэффициент ФУ СС; $k_{\text{ФУ треб}}$ – требуемый коэффициент ФУ СС.

Выходные результаты методики обеспечения ФУ СС в условиях воздействия ДФ и наличия конфликта в системе: $\langle W(\vec{E}, j), F \rangle$.

Перейдем к описанию исходных данных.

Исходные данные методики:

Данные, характеризующие структуру СС: количество элементов в системе $i = \overline{1, N_y}$, где N_y – общее количество элементов в системе, количество связей, соединяющих элементы СС, $k = \overline{1, L}$, где L – общее количество связей в системе, количество технических средств, находящихся на элементах СС и позволяющих формировать связи, при этом направления связи между элементами задаются парами $\langle i, m \rangle \in L$, $i \in N_y$, $m \in N_y$, $j = \overline{1, N_c}$, где N_c – общее количество технических средств связи на элементах СС и $l(j)$ – количество режимов функционирования каждого j -го средства связи, $\lambda_G(i, \lambda_i)$ – множество, характеризующее нагрузку в виде интенсивностей потока сообщений λ_i от i -го УС.

Данные, характеризующие функциональную составляющую СС: множество целей СС $A = \{A_1, A_2, \dots, A_a\}$, множество требований, предъявляемых к СС $T = \{T_1, T_2, \dots, T_n\}$, множество функций, выполняемых СС $F = \{F_1, F_2, \dots, F_c\}$, множество задач, решаемых СС

$Z = \{Z_1, Z_2, \dots, Z_d\}$ и множество ресурсов СС $E = \{E_1, E_2, \dots, E_m\}$, обеспечивающих ее функционирование.

Данные, характеризующие потребности СУ: множество целей СС $A = \{A_1, A_2, \dots, A_d\}$, которые ей необходимо достичь в интересах СУ, множество требований, предъявляемых к системе связи со стороны СУ $T = \{T_1, T_2, \dots, T_n\}$, множество функций, выполняемых системой $F = \{F_1, F_2, \dots, F_c\}$, которые ей необходимо выполнить в интересах СУ, множество задач, решаемых системой связи в интересах СУ $Z = \{Z_1, Z_2, \dots, Z_d\}$ и множество ресурсов системы $E = \{E_1, E_2, \dots, E_m\}$, обеспечивающих ее функционирование и необходимых для удовлетворения потребностей СУ.

Исходные данные, характеризующие противоборствующую сторону: $N_{дв}$ – количество средств, предназначенных для обнаружения воздействия ДФ; $L_{дв}(n_{дв}, i)$ – множество средств, предназначенных для обнаружения воздействия ДФ $n_{дв}$, $n_{дв} = \overline{1, N_{дв}}$ находящихся на i -м, $i \in N_y$ узле (элементе) СС; $\lambda_{дв}(n_{дв}, \lambda_{n_{дв}})$ – множество, характеризующее интенсивность воздействия ДФ на элементы СС, определяемое по воздействию на средства обнаружения воздействия в виде интенсивности потока $\lambda_{n_{дв}}$ от $n_{дв}$ -го средства.

Исходные данные, характеризующие достоверность (α) и точность (ε) моделирования.

Показатели и критерии, ограничения и допущения, принятые в методике:

Показатель: вероятность нарушения устойчивого функционирования СС.

Критерий: $P_{наруш\ функ} \leq P_{наруш\ функ\ зад}$; $t_{уст\ функ} > T_{функ\ зад}$.

Допущения и ограничения:

- на период функционирования (моделирования) СС ее структура задана и остается неизменной;
- воздействия, приводящие к нарушению структуры СС, т.е. удаление УС и линий связи не рассматривается;
- узлы СС способны выполнить весь перечень заданных функций и задач;
- пропускная способность линий связи между узлами СС, линий привязки элементов СС и других систем известна и позволяет системе выполнять свое целевое предназначение;
- передача сообщений пользователей между узлами осуществляется по известному алгоритму. Для передачи сообщений в СС выбирается кратчайший маршрут, включающий минимальное количество промежуточных узлов;

- СС имеет ограниченный ресурс, позволяющий варьировать параметрами элементов;
- не рассматривается восстановление работоспособности СС из состояния полного разрушения системы.

Область применения: методика применима для ситуаций нарушения функционирования сложных технических систем, таких как системы и сети связи, информационные системы, информационно-телекоммуникационные системы, качество и эффективность выполнения которых определяются требованиями к ним.

Последовательность проведения расчетов по методике. Как следует из принятых ограничений и допущений, СС функционирует с выполнением требований, предъявляемых к ней. На нее осуществляется воздействие различных ДФ, приводящих к нарушению процесса функционирования системы, т.е. невыполнению задач и функций системы.

Последовательность применения разработанной методики обеспечения ФУ СС состоит из этапов, представленных на рисунке 1. На первом этапе производится ввод исходных данных. Далее разрабатывается структурно-функциональная модель СС, позволяющая определять ее возможности по выполнению функций и задач СС и СУ.

На втором этапе осуществляется контроль выполнения профиля функционирования СС. На третьем этапе проверяется наличие конфликтов в системе. При обнаружении конфликта, обусловленного отличием профиля процесса функционирования СС от профиля функционирования СС, причины возникновения конфликта определяют на четвертом этапе.

Под профилем функционирования системы понимается характеристика системы, характеризующая ее потребность в выполнении целевого предназначения системы, определяемого взаимосвязанным выполнением целей, функций, задач и требований, предъявляемых к системе. В работе профиль функционирования системы соответствует профилю плана и обозначается Q .

Профиль процесса функционирования системы – характеристика процесса функционирования системы показывающая в любой момент времени степень достижения целевого предназначения системы, выполнения профиля функционирования системы, а также количество выполненных и выполняемых целей, функций, задач, требования, предъявляемых к системе и ее элементам. В работе обозначается Q_p .

На пятом этапе проверяется, обусловлен ли конфликт отсутствием ресурса для выполнения текущего профиля без его изменения (возможность выполнения текущего профиля функция СС

существующей структурой системы). Если нет, то на 6 этапе проверяется возникновение конфликта из-за появления новой задачи, функции, что определяет потребность изменения профиля функционирования СС. На 7 этапе определяется потребный ресурс СС для выполнения новой задачи, функции. Если да, то на 8 этапе определяются функции и задачи текущего профиля функционирования СС, которые будут не выполнены из-за отсутствия ресурса для них.

На 9 этапе оценивается необходимость синтеза СС сначала по функциональному предназначению, потом по структуре системы.

При отсутствии необходимости синтеза СС на 10 этапе используется ресурс из резерва или ресурсы, запланированные для выполнения других задач, функций, которые в данный момент не задействованы для выполнения других задач, функций.

На 11 этапе, при необходимости, осуществляют синтез СС для обеспечения выполнения задач, функций.

На 12 этапе изменяют профиль функционирования СС и предоставляют информацию о произведенном синтезе системы и измененном профиле на этапе 1, где корректируются исходные данные для системы.

При достижении требуемого (заданного) времени функционирования СС на этапе 13 оценивают необходимость дальнейшего контроля СС.

Порядок осуществления синтеза СС, соответствующий блоку 11 рисунка 1, включает этапы, представленные на рисунке 2, которые рассмотрим ниже.

Действия, выполняемые в блоке 1, соответствуют первому этапу методики. Исходные данные формируются в системе контроля процесса функционирования СС и поступают в базу данных, где формируются характеристики профиля процесса функционирования СС и профиля функционирования СС.

В блоке 2 на основании применения структурно-функциональной модели СС, применения методов формирования профиля СС, модели контроля процесса функционирования СС и методики контроля процесса функционирования системы, осуществляется формирование профилей и контроль выполнения профиля функционирования СС.

В блоке 3 осуществляется сравнение профилей. Если условие выполняется, то продолжается контроль выполнения профиля, если условие не выполняется, и профили не соответствуют, то в блоке 4 определяют причину несоответствия профилей.




Рис. 1. Блок-схема последовательности применения методики

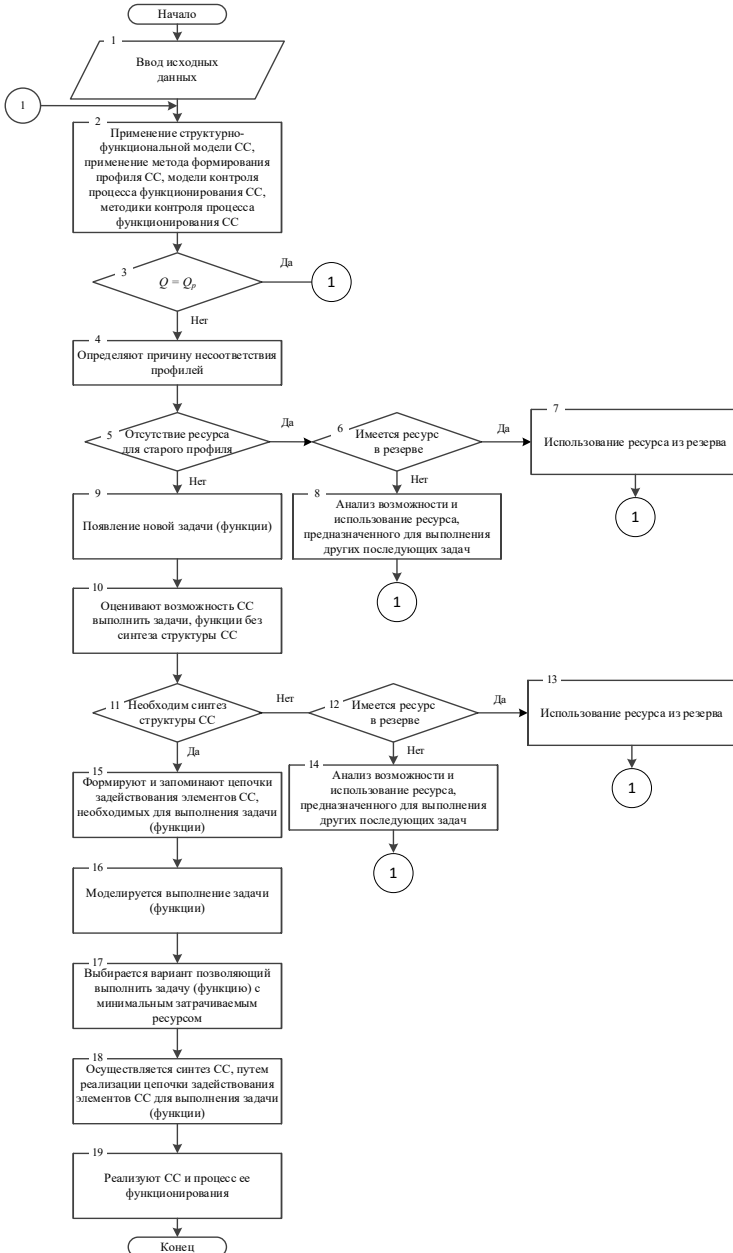


Рис. 2. Блок-схема синтеза СС для обеспечения ФУ

В блоке 5 проверяется наличие ресурса для выполнения профиля функционирования СС. Если ресурс отсутствует, то в блоке 6 проверяется наличие требуемого ресурса в резерве. Если в резерве ресурс есть, то он используется в блоке 7 для выполнения профиля функционирования СС. В противном случае используется ресурс, предназначенный для выполнения других задач в блоке 8.

Если ресурс имеется для выполнения текущего профиля функционирования СС, а конфликт обусловлен появлением новой задачи, функции блок 9, то оценивается возможность СС выполнить ее новую задачу, функцию без синтеза структуры СС блок 11.

Если необходимости синтеза структуры нет, то в блоке 12 проверяется наличие ресурса в резерве для выполнения новой задачи, функции. Если резерв имеется, переходим к блоку 13 и используем его для выполнения новой задачи, функции, если он отсутствует, то переходим к блоку 14 – анализируется возможность использования ресурса, предназначенного для выполнения других последующих задач, функций, и при наличии такой возможности он используется.

Если присутствует необходимость синтеза СС, то переходят к блоку 15, где формируют и запоминают варианты (цепочки) использования элементов СС, для выполнения новой задачи, функции.

В блоке 16 моделируется выполнение цепочкой элементов новой задачи, функции.

В блоке 17 выбирается вариант задействования элементов СС, позволяющий выполнить задачу, функцию с минимальными затратами ресурсов.

В блоке 18 осуществляется синтез СС путем реализации цепочек задействования ее элементов для выполнения новой задачи, функции. После получения необходимых данных их запоминают и реализуют функционирование СС (блок 19).

2. Определение интенсивности синтеза СС и ее элементов в условиях появления конфликтов в ней. Определение интенсивности синтеза СС в разработанной методике выполнено с помощью математической модели, описывающей процесс функционирования СС, который может быть представлен в виде графа состояний СС (рисунк 3).

Под интенсивностью синтеза СС понимается характеристика перехода системы из текущего функционально устойчивого состояния в другое функционально устойчивое состояние, которое позволяет обеспечить реализацию целевого предназначения СС.




Рис. 3. Граф состояний СС

На рисунке 3, ребра графа показывают переходы из одной вершины в другую, которые в графе отображают состояния процесса функционирования системы.

Предлагается рассмотреть пять состояний СС (S_1 - S_5), описание которых представлено в таблице 1. Рассмотренное множество состояний представляет собой полную группу событий. Каждое состояние характеризуется условиями функционирования СС в любой момент времени. Процесс перехода из одного состояния в другое обусловлен особенностями и характером рассматриваемого процесса функционирования СС.

Таблица 1. Дискретные состояния графа состояний СС

№ п/п	Состояние	Процессы, характеризующие состояние СС	Входящий поток	Исходящий поток
1	S_1	Требования, предъявляемые к СС выполняются в процессе ее функционирования, обеспечиваются заданные требования по ФУ. Формируется профиль функционирования СС и профиль процесса функционирования СС в процессе контроля функционирования СС.	$\lambda_{31}, \lambda_{51}$	λ_{13}
2	S_2	Прекращение устойчивого функционирования СС	λ_{32}	
3	S_3	Выявление системой контроля конфликта, обусловленного отличием профилей	λ_{13}	$\lambda_{31}, \lambda_{32}, \lambda_{34}$
4	S_4	Формирование вариантов устранения конфликта (формирование нового профиля плана), моделирование процесса функционирования СС в соответствии с новым вариантом профиля плана	λ_{34}	λ_{45}
5	S_5	Синтез СС в соответствии с новым профилем плана и полученными данными моделирования	λ_{45}	λ_{51}

Процесс формирования графа, представленного на рисунке 3, показан на рисунке 4. Его можно описать с помощью двух состояний (рисунок 4(а)), которые показывают, что система либо функционально устойчива, т.е. выполняются заданные показатели функциональной устойчивости (состояние 1), или устойчивость функционирования системы связи снижена до недопустимого уровня (состояние 2), т.е. происходит отклонение характеризующих ее показателей ниже области допустимых значений. Нарушение функционирования системы обусловлено воздействием различных ДФ независимо от их природы. Результатом такого воздействия является отсутствие у системы возможности выполнить необходимый перечень задач и функций (состояние 3) (рисунок 4(б)), что характеризуется конфликтом невозможности выполнения профиля функционирования СС. При нарушении функционирования СС (возникновении конфликта) необходимо обеспечить переход СС из состояния 2 в 1. В данном случае предлагается рассмотреть два дополнительных состояния: формирование вариантов устранения конфликта (формирование нового профиля плана), моделирование функционирования СС в соответствии с новым профилем плана (состояние 4) и преобразования СС в соответствии с ним – состояние синтеза СС (состояние 5) (рисунок 4(в)).

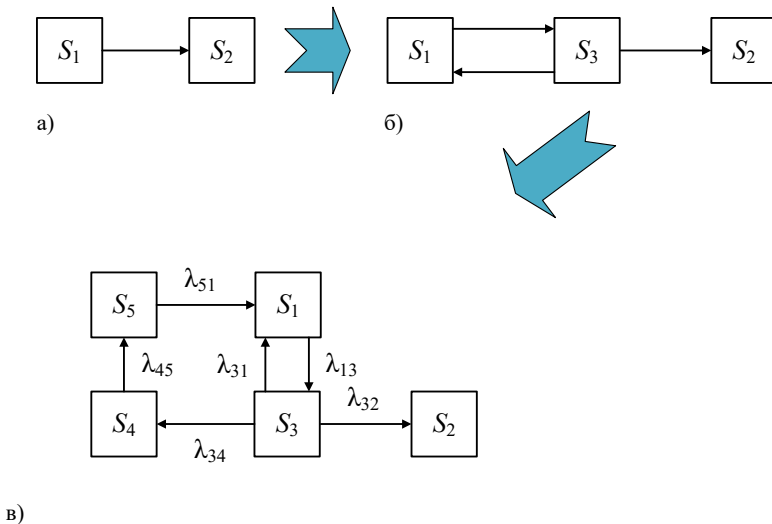


Рис. 4. Логика построения графа, представленного на рисунке 3

Корректность и адекватность представленной модели основана на ее соответствии общим закономерностям функционирования систем.

Оценка эффективности функционирования СС с возможностью синтеза ее для обеспечения ФУ связана с необходимостью моделирования в режиме реального времени. Это обуславливает целесообразность использования математического аппарата Марковских случайных процессов, необходимое условие которого – потоки событий являются простейшими, т. е. обладают свойствами стационарности, ординарности и не имеют последствий [34].

Возникновение конфликтов и переход из одного состояния в другое является случайным процессом, поэтому процесс функционирования СС, описываемый графом, представленным на рисунке 3, можно представить, как Марковский случайный процесс с дискретными состояниями и непрерывным временем [34, 35].

Процесс перехода из одного состояния системы в другое происходит под действием потоков событий, которые описываются интенсивностями λ_{ij} . Для описания процесса функционирования СС рассмотрим следующий перечень потоков событий:

λ_{13} – поток заявок воздействия на СС различных дестабилизирующих факторов – интенсивность возникновения конфликтов в СС;

λ_{32} – поток заявок при невозможности выполнения функций и задач – переход в нерабочее состояние;

λ_{31} – поток заявок после воздействия дестабилизирующих факторов на переход в функционально устойчивое состояние (воздействие на СС ДФ не привело к нарушению ее устойчивого функционирования);

λ_{14} – поток заявок на формирование возможных вариантов устранения конфликта и нового профиля функционирования СС, моделирование возможных вариантов устранения конфликта и нового профиля;

λ_{45} – поток заявок на синтез СС в соответствии с одним из вариантов устранения конфликта и новым профилем функционирования СС (профилем плана);

λ_{51} – поток заявок на переход СС в функционально устойчивое состояние.

Использование предложенной модели способствует поиску необходимых значений интенсивностей синтеза СС, при возникновении конфликтов в ней, обусловленных воздействием ДФ,

что позволит обеспечить достижение системой своего целевого предназначения.

Для различных сценариев состояния системы в условиях воздействия ДФ СС переходит из текущего состояния S_j в состояние S_j (поток интенсивностей λ_{ij}), которое может характеризоваться конфликтом.

Пусть первоначально моделируемая СС находится в состоянии, в котором обеспечивается ее ФУ в соответствии с заданными требованиями – S_1 . Процесс перехода из данного устойчивого состояния в другое – неустойчивое, обусловлен изменением обстановки, в которой она функционирует.

В соответствии с графом состояний СС (рисунок 3) переход ее в функционально устойчивое состояние может происходить в следующих случаях:

– воздействия ДФ, не приводящих к конфликту в системе. При этом она переходит в ФУ состояние, которое определяется нахождением значений параметров, характеризующих состояние системы, в пределах заданной нормы. Такое состояние можно рассматривать, как ситуацию устранения воздействия ДФ и определения возможности обеспечения ФУ СС без необходимости синтеза системы и формирования нового профиля плана (замена элемента системы, ресурса, взятого из резерва или ресурса, спланированного для другой задачи). Переход в такое состояние происходит под действием потока заявок λ_{31} ;

– осуществления синтеза системы в соответствии с профилем функционирования СС, необходимого для устранения возникшего конфликта в системе, после соответствующих этапов моделирования. Переход в такое состояние происходит под действием потоков заявок λ_{34} , λ_{45} , λ_{51} .

Нарушение функционирования СС, обусловленное возникновением конфликта и (или) не выполнением требований, предъявляемых к ней, влечет переход системы из состояния выявления конфликта в состояние поиска вариантов его устранения и моделирования функционирования системы (формирования нового профиля плана). Переход в такое состояние происходит под воздействием потока заявок λ_{43} .

Обеспечение процесса устойчивого функционирования системы в пределах требуемого интервала значений параметров, характеризующих выполнение требований, предъявляемых к СС, осуществляется путем изменения интенсивности потоков заявок на

переход системы из состояния обнаружения конфликта в состояния ее моделирования и синтеза.

В процессе функционирования системы происходит измерение параметров, характеризующих процессы, происходящие в ней в соответствии с алгоритмом (рисунок 2). Формируется множество вариантов устранения конфликта, моделируется функционирование системы с использованием таких вариантов в состоянии S_4 , после чего происходит измерение значений параметров, характеризующих функционирование СС и выбор оптимального варианта ее синтеза. В состоянии S_5 осуществляется синтез системы, в соответствии с профилем плана, что под действием потока заявок λ_{51} позволяет перевести систему в функционально устойчивое состояние.

Интенсивность изменения параметров зависит от активности воздействия ДФ, интенсивности и количества возникающих конфликтов в СС, а также возможностей СС по реализации профиля плана.

Для описания процесса функционирования СС, представленного графом на рисунках 3 и 4, необходимо разработать математическую модель функционирования СС.

В рассматриваемом случае СС в любой момент времени может находиться в одном из состояний S_1, S_2, \dots, S_5 или переходить из одного состояния в другое. Под вероятностью i -го состояния будем понимать такую вероятность $p_i(t)$, для которой СС в момент времени t будет находиться в S_i состоянии. Согласно [36] для рассматриваемого графа составляются уравнения Колмогорова – линейные дифференциальные уравнения (ЛДУ) с неизвестными функциями $p_i(t)$:

$$\left\{ \begin{array}{l} \frac{dp_1(t)}{dt} = \lambda_{31}p_3(t) + \lambda_{51}p_5(t) - \lambda_{13}p_1(t); \\ \frac{dp_2(t)}{dt} = \lambda_{32}p_3(t); \\ \frac{dp_3(t)}{dt} = \lambda_{13}p_1(t) - (\lambda_{31} + \lambda_{32} + \lambda_{34})p_3(t); \\ \frac{dp_4(t)}{dt} = \lambda_{34}p_3(t) - \lambda_{45}p_4(t); \\ \frac{dp_5(t)}{dt} = \lambda_{45}p_4(t) - \lambda_{51}p_5(t); \\ \sum_{i=1}^5 p_i(t) = 1. \end{array} \right. \quad (2)$$

Выбор начальных условий определяется исходя из возможных состояний СС. Начальное состояние описывается вектором вероятностей начальных состояний Марковской цепи:

$$p_i(0) = \left((1 - P_{\text{наруш функц}}) P_{\text{наруш функц}} \ 0 \ 0 \ 0 \right). \quad (3)$$

Задавая численные значения интенсивностей λ (таблица 1) и переходя к непрерывному времени $t \rightarrow \infty$, решается система ЛДУ (2) с постоянными коэффициентами (однородный Марковский процесс). Для любого момента времени сумма всех вероятностей состояний системы равна единице:

$$\sum_{i=1}^5 p_i(t) = 1. \quad (4)$$

Значения интенсивностей заявок определяются в соответствии с требованиями, заданными стратегиями моделирования, выбираемыми в зависимости от исходных данных.

Постановка задачи на моделирование:

Требуется оценить вероятность обеспечения функциональной устойчивости процесса функционирования СС в зависимости от интенсивностей возникновения конфликтов в ней.

Исходные данные:

- множество рассматриваемых состояний СС;
- уравнения Колмогорова (2), характеризующие функционирование рассматриваемой системы;
- вектор вероятностей начальных состояний СС (3), описываемой графом (рисунок 3);
- нормировочное условие (4);
- интенсивности потока событий, соответствующие сценариям моделирования СС.

Решения задач для системы ЛДУ можно разделить на три группы [36]: приближенно-аналитические методы; графические или машинно-графические методы; численные методы.

Численные методы предполагают получение приближенных значений p_i искомых решений $p(t)$ на некотором интервале $t \in [t_0; t_1]$. Применение к полученной числовой таблице значений p_i способа аппроксимации, например, сплайн-интерполяции, позволяет иметь приближенное решение $p(t)$ на заданном интервале времени, что по сравнению с другими методами решения, позволяет решать

поставленную прикладную задачу и оценивать ее возможности [35, 37].

Недостатки методов Эйлера и других численных методов решения более высоких порядков [36, 38], заключающиеся в необходимости вычисления на каждом шаге частных производных функции $S(t, p)$, что приводит к большой вычислительной сложности, предопределили выбор в качестве решения системы ЛДУ классического метода – метода Рунге-Кутты четвертого порядка с фиксированным шагом интегрирования, имеющего вид (5), где h – приращение, соответствующее шаговой поправке Эйлера, Δp_i – средневзвешенная величина поправок $h\eta^1_i, h\eta^2_i, h\eta^3_i, h\eta^4_i$ каждого этапа интегрирования (с весовыми коэффициентами 1/6, 2/6, 2/6, 1/6 соответственно), то есть результат усреднения с указанными коэффициентами четырехэтапных поправок [37].

Первый этап соответствует применению явного метода Эйлера, второй и третий – уточненных методов Эйлера, а четвертый – неявного метода. Геометрическое толкование метода известно [37]:

$$\begin{cases} \eta_1^i = S(t_i, p_i); \\ \eta_2^i = S(t_i + h/2, p_i + \eta_1^i \cdot h/2); \\ \eta_3^i = S(t_i + h/2, p_i + \eta_2^i \cdot h/2); \\ \eta_4^i = S(t_i + h, p_i + \eta_3^i \cdot h); \\ \Delta p_i = (\eta_1^i + 2\eta_2^i + 2\eta_3^i + \eta_4^i) \cdot h/6; \\ p_{i+1} = p_i + \Delta p_i. \end{cases} \quad (5)$$

Использование метода Рунге-Кутты обусловлено тем, что для решения (2) применение методов Эйлера и исключения не позволяет решить данное уравнение из-за необходимости решения уравнения, связывающего функции $p_i(t)$ вместе.

Приводим систему (2) к векторному представлению – столбец D , где каждый элемент соответствует правой части определенного дифференциального уравнения в системе:

$$D(t, p) = \begin{cases} \lambda_{31}p_3(t) + \lambda_{51}p_5(t) - \lambda_{13}p_1(t); \\ \lambda_{32}p_3(t); \\ \lambda_{13}p_1(t) - (\lambda_{31} + \lambda_{32} + \lambda_{34})p_3(t); \\ \lambda_{34}p_1(t) - \lambda_{45}p_4(t); \\ \lambda_{45}p_4(t) - \lambda_{51}p_5(t). \end{cases} \quad (6)$$

Используя известный [37, 38] порядок решения системы ЛДУ методом Рунге-Кутты, учитывая вектор вероятностей начальных состояний $p_i(0)$, интервал интегрирования $[t_0; t_1]$ и число этапов интегрирования n , производится расчет для заданных значений интенсивностей событий $\lambda_{ij} = \text{const}$ (Марковский однородный процесс) (таблица 2). Это позволит получить приближенные значения p_i искомых решений $p(t)$ на некотором интервале $t \in [t_0; t_1]$ (таблица 3).

Таблица 2. Стратегии моделирования процесса функционирования СС

Интенсивность потока событий	λ	Значения интенсивностей потоков событий для стратегии										
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
интенсивность воздействия на СС ДФ, характеризующая возникновение в ней конфликта	λ_{13}	1	10	10	50	50	50	100	100	100	100	100
интенсивность перехода в состояние планирования синтеза и моделирования устранения конфликта	λ_{34}	0	0	5	0	10	10	0	0	10	20	30
интенсивность перехода в состояние синтеза системы	λ_{45}	0	0	5	0	10	10	0	0	10	20	30
интенсивность перехода в рабочее состояние после синтеза СС или ее элемента	λ_{51}	0	0	5	0	10	10	0	0	10	20	30
интенсивность, характеризующая переход СС в ФУ состояние, в котором отсутствует необходимость синтеза СС	λ_{31}	1	9	9	45	45	40	99	90	90	90	90
интенсивность перехода в функционально неустойчивое состояние, когда конфликт устранить не получается	λ_{32}	0	1	1	5	5	10	1	10	10	10	10

Для получения приближенных решений $p(t)$ на заданном интервале времени используем сплайн-интерполяцию к полученной числовой таблице значений p_i .

Для оценки ФУ процесса функционирования СС в любой момент времени (шаге модельного времени) при различных стратегиях, характеризующих возникновение конфликтов в системе (таблица 2), предлагается использовать метод, который позволяет получить вероятностно-временные характеристики, описывающие состояния СС в условиях воздействия ДФ и возникновения конфликтов в ней.

Таблица 3. Приближенные решения $p_i(t)$

Этапы интегрирования, n	Точка интервала интегрирования, $[t_0, t_1]$	$p(t)$				
		$p_1(t)$	$p_2(t)$	$p_3(t)$	$p_4(t)$	$p_5(t)$
1	t_0	$p_1(t_0)$	$p_2(t_0)$	$p_3(t_0)$	$p_4(t_0)$	$p_5(t_0)$
...
n	t_1	$p_1(t_1)$	$p_2(t_1)$	$p_3(t_1)$	$p_4(t_1)$	$p_5(t_1)$

На основе формального описания процесса функционирования СС получаем вероятность нарушения функционирования СС $P_{\text{нарушфункц}} = p_2(t)$.

Требуется оценить функциональную устойчивость предлагаемой модели, описывающей процесс функционирования СС для различных сценариев (исходных данных). Зададим граничные значения в различных стратегиях функционирования взаимодействующих сторон.

Для примера рассмотрим стратегию С2 и исходные данные для нее. Определяем интервал интегрирования $t_0 = 0, t_1 = 1$ и число этапов интегрирования $n = 1000$. Выбор интервала и этапов определяется точностью и быстродействием проводимого исследования, а также потребностями исследователя. Далее в соответствии со стратегией С2 осуществляется векторное представление выражения (2), где каждый элемент соответствует правой части дифференциального уравнения в системе с заданными интенсивностями:

$$D(t, p) = \begin{pmatrix} 9p_3(t) + 0p_5(t) - 10p_1(t); \\ 1p_3(t); \\ 10p_1(t) - (9 + 1 + 0)p_3(t); \\ 0p_1(t) - 0p_4(t); \\ 0p_4(t) - 0p_5(t). \end{pmatrix} \quad (7)$$

Производим расчет по методу Рунге-Кутты со средневзвешенной величиной поправок каждого этапа интегрирования (5) и получаем приближенные значения p_i на интервале с фиксированным шагом интегрирования 10^{-3} (таблица 4).

Таблица 4. Приближенные значений $p_i(t)$ для стратегии С2

Этапы интегрирования, n	Точка интервала интегрирования, $[t_0, t_1]$	$p(t)$				
		$p_1(t)$	$p_2(t)$	$p_3(t)$	$p_4(t)$	$p_5(t)$
1	0,001	0.99	$4.967 \cdot 10^{-6}$	$9.901 \cdot 10^{-3}$	0	0
2	0,002	0.98	$1.974 \cdot 10^{-5}$	0.02	0	0
3	0,003	0.971	$4.411 \cdot 10^{-5}$	0.029	0	0
...
999	0,999	0.299	0.385	0.316	0	0
1000	1,000	0.299	0.385	0.315	0	0

Применяя к полученной числовой таблице значений p_i способ аппроксимации (сплайн-интерполяции), получаем приближенное решение $p(t)$ на заданном интервале времени. Графики зависимостей вероятностей состояний процесса функционирования СС $p_1(t), p_2(t), \dots, p_5(t)$ для значений интенсивностей событий, соответствующие стратегии С2 (таблица 2), представлены на рисунке 5.

Характер выявленных зависимостей (рисунок 5) говорит о том, что система еще не достигла стационарного состояния. При этом низкая интенсивность воздействия ДФ и возникновения конфликтов в СС позволяет ей оставаться в функционально устойчивом состоянии.

На основании представленного выше примера, для всех остальных стратегий функционирования СС (таблица 2), рассчитываются вероятностные и временные характеристики для соответствующих интенсивностей.

Получаем приближенные значения p_i на интервале $t \in [t_0; t_1]$ с фиксированным шагом интегрирования 10^{-3} для значений интенсивностей потоков событий, соответствующих стратегиям С1, С3 – С11 (увеличение интенсивности воздействия ДФ и появления конфликтов в СС (таблица 2), сплайн-интерполяция значений которых представлена на графиках зависимостей вероятностей состояний от времени (рисунки 6 – 15).




Рис. 5. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией C2




Рис. 6. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией C1

Характер выявленных зависимостей (рисунки 6, 7) говорит о том, что система, аналогично сценарию C2, еще не достигла стационарного состояния. При этом низкая интенсивность воздействия ДФ и возникновения конфликтов в СС позволяет системе связи оставаться в функционально устойчивом состоянии. Рассмотрим поведение системы при увеличении интенсивности на переход в моделирование и синтез СС.




Рис. 7. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией C3




Рис. 8. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией C4

Характер выявленных зависимостей (рисунок 8) говорит о том, что система, аналогично сценариям C1, C2, C3 еще не достигла стационарного состояния. Время нарушения устойчивого функционирования системы связи с вероятностью $P_{\text{нарушфункц}} = 0,7$ составляет 480 ед. модельного времени. Далее рассмотрим увеличение

интенсивностей синтеза системы при сохранении интенсивностей перехода в нерабочее состояние. Видно (рисунок 9), что с увеличением интенсивностей на синтез системы время устойчивого функционирования СС с вероятностью $P_{\text{нарушфункц}} = 0,7$ увеличивается и составляет 985 ед. модельного времени. Рассмотрим случай увеличения интенсивности перехода в функционально неустойчивое состояние. С увеличением интенсивностей отказов (рисунок 10), обусловленных конфликтами и воздействиями ДФ время нарушения устойчивого функционирования СС с вероятностью $P_{\text{нарушфункц}} = 0,7$ уменьшается и составляет 458 ед. модельного времени.




Рис. 9. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией С5




Рис. 10. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией С6

При увеличении интенсивности воздействия на систему ДФ и возникновения большего количества конфликтов без синтеза системы получены зависимости, характер которых (рисунок 11) говорит о том, что система, аналогично сценариям С1 и С2, еще не достигла стационарного состояния. При этом на всем времени моделирования система является функционально устойчивой.

Увеличение интенсивности воздействия на систему ДФ приводит к возникновению большего количества конфликтов, а также увеличению интенсивностей перехода в нерабочее состояние (рисунок 12). Характер полученных зависимостей показывает, что система не достигла стационарного состояния. При этом с увеличением интенсивностей отказов, обусловленных конфликтами и воздействиями ДФ, время нарушения устойчивого функционирования СС с вероятностью $P_{\text{нарушфункц}} = 0,7$ составляет 240 ед. модельного времени.




Рис. 11. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией С7




Рис. 12. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией С8

Рассмотрим поведение системы при дальнейшем увеличении интенсивности перехода в состояния моделирования и синтеза СС с последующим переходом в функционально устойчивое состояние.




Рис. 13. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией С9




Рис. 14. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией С10

При увеличении интенсивности воздействия на систему ДФ и, вследствие этого, возникновении большего количества конфликтов, а также увеличении интенсивностей перехода в состояния моделирования и синтеза СС получены зависимости, характер которых (рисунок 13) показывает, что с увеличением интенсивностей перехода в состояние синтеза и возвращения в функционально устойчивое состояние СС время нарушения ее устойчивого функционирования с вероятностью $P_{\text{нарушфункц}} = 0,7$ составляет 492 ед. модельного времени,

что говорит об эффективной работе системы контроля и восстановления работоспособности системы и ее элементов.

При увеличении интенсивности перехода в состояния моделирования и синтеза СС получены зависимости, характер которых (рисунок 14) говорит о том, что с увеличением интенсивностей перехода в состояние синтеза и возвращения в функционально устойчивости состояние СС время нарушения устойчивого функционирования СС с вероятностью $P_{\text{нарушфункц}} = 0,7$ составляет 509 ед. модельного времени, что говорит об эффективной работе системы контроля и восстановления работоспособности системы и ее элементов.

Таким образом, дальнейшее увеличение интенсивностей потоков событий на моделирование и синтез СС при сохраняющихся интенсивностях потока событий воздействия ДФ и возникновения конфликтов закономерно приводит к снижению вероятности нарушения функционирования СС (рисунок 15). Время нарушения устойчивого функционирования СС с вероятностью $P_{\text{нарушфункц}} = 70\%$ составляет 521 ед. модельного времени.

Изменение интенсивностей заявок соответствует изменению стратегий взаимодействующих сторон и, как следствие, изменению вероятности нарушения функционирования СС (таблица 5). Гистограмма зависимости представлена на рисунке 16.

Таблица 5. Сводная таблица показателей функциональной устойчивости СС

№	Интенсивность воздействия ДФ, характеризующая возникновение конфликтов	Интенсивность возникновения неустраиваемых конфликтов в СС	Интенсивность синтеза СС	Вероятность нарушения функционирования $P_{\text{нарушфункц}}$ ($tф = 80 с$)	Среднее время устойчивого функционирования СС $P_{\text{нарушфункц}} > 70 \%$
C1	1	0	0	0	> 1000
C2	10	1	0	0.319	> 1000
C3	10	1	5	0.182	> 1000
C4	50	5	0	0.868	480
C5	50	5	10	0.619	> 1000
C6	50	10	10	0.835	503
C7	100	1	0	0.329	> 1000
C8	100	10	0	0.983	240
C9	100	10	10	0.842	492
C10	100	10	20	0.84	509
C11	100	10	30	0.838	521




Рис. 15. Расчет вероятностей нахождения системы в моделируемых состояниях в соответствии со стратегией С11




Рис. 16. Гистограмма зависимости вероятности нарушения устойчивого функционирования СС от стратегии ее функционирования

Разработанная модель процесса функционирования СС в условиях воздействия различных ДФ, обуславливающих возникновение конфликтов в СС, учитывает влияние и интенсивность возникновения в ней конфликтов. Процесс обеспечения ФУ СС сводится к поиску стратегии синтеза СС в зависимости от интенсивности воздействия ДФ, приводящей к увеличению времени функционирования СС с заданной допустимой вероятностью ФУ.

Как видно из таблицы 5 и рисунка 16 с увеличением интенсивности возникновения конфликтов в СС вероятность нарушения устойчивого функционирования падает. При этом при равных условиях низкая интенсивность перехода в неработоспособное состояние СС позволяет обеспечить более длительное нахождение системы в функционально устойчивом состоянии.

С увеличением интенсивности возникновения перехода в режимы моделирования и синтеза системы с последующим переходом в режим устойчивого функционирования вероятность нарушения устойчивого функционирования падает, а время устойчивого функционирования СС увеличивается. При этом при равных условиях низкая интенсивность перехода в неработоспособное состояние СС позволяет обеспечить более длительное нахождение системы связи в функционально устойчивом состоянии.

Модель функционирования СС, как составная часть методики обеспечения функциональной устойчивости СС, за счет выявления конфликтов в СС, выполнения синтеза СС и ее элементов, позволяет определить зависимость процесса устойчивого функционирования СС от механизма моделирования (планирования), синтеза СС и ее

элементов. Кроме этого, оценивать эффективность системы контроля процесса функционирования СС и обоснованно выбирать алгоритмы обеспечения функциональной устойчивости.

4. Заключение. Количество ДФ, влияющих на функционирование, как отдельных элементов СС, так и всей системы, с каждым годом растет. Это связано, в первую очередь, с появлением новых средств воздействия у злоумышленников, совершенствованием их тактико-технических характеристик. Успешность реализации таких воздействий зависит от многих факторов, например, характера воздействия, средств и квалификации злоумышленника, используемой в СС системы защиты и контроля и т.д. В результате таких воздействий может нарушаться устойчивость функционирования СС, что недопустимо для критически важных объектов.

С целью уменьшения вероятности нарушения ФУ СС разработана методика обеспечения функциональной устойчивости СС в условиях воздействия ДФ, основанная на выявлении конфликтов в СС, обусловленных несоответствием профиля процесса функционирования СС профилю функционирования СС.

Практическая значимость методики заключается в том, что она позволяет выявлять зависимость времени устойчивого функционирования СС с заданной вероятностью от интенсивности перехода в состояние синтеза СС и ее элементов и интенсивности воздействия ДФ, появления конфликтов в СС, иными словами, определять время устойчивого функционирования СС.

Разработанная методика обеспечения функциональной устойчивости СС может использоваться лицами, принимающими решение, и должностными лицами, которые занимаются планированием связи, при решении расчетных задач, в ходе оценки обстановки и разработки предложений по управлению связью.

Полученные результаты являются основой и определяют наиболее перспективные направления для разработки подходов по обеспечению ФУ СС в условиях воздействия ДФ различной природы в ходе построения, модернизации и наращивании системы связи, а также при планировании связи.

Литература

1. Кондрашов Ю.В., Сатдинов А.И., Синюк А.Д., Остроумов О.А. Концептуальная модель контроля функций системы связи для выявления конфликтных ситуаций // Т-Comm – Телекоммуникации и транспорт. 2022. Т. 16. № 5. С. 21–27. DOI: 10.36724/2072-8735-2022-16-5-21-27.
2. Макаренко С.И. Модели системы связи в условиях преднамеренных дестабилизирующих воздействий и ведения разведки. Монография. // СПб.: Научное издание, 2020. 337 с.

3. Остроумов О.А. Проблема обеспечения функциональной устойчивости систем критически важных объектов // Электросвязь. 2022. № 1. С. 38–42. DOI: 10.34832/ELSV.2022.26.1.005.
4. Тарасов А.А. Функциональная реконфигурация отказоустойчивых систем: монография // М.: Логос. 2012. 152 с.
5. Стародубцев Ю.И., Закалкин П.В., Иванов С.А. Техносферная война как основной способ разрешения конфликтов в условиях глобализации // Военная мысль. 2020. № 10. С. 16–21.
6. Остроумов О.А. Модель контроля функционирования системы связи // Известия Тульского государственного университета. Технические науки. 2022. № 3. С. 300–309.
7. Лаута О.С., Баленко Е.Г., Федоров В.Х., Лепешкин О.М., Остроумов О.А. Метод построения профиля функционирования сложной технической системы // Инженерный вестник Дона. 2023. № 2(98). С. 48–77. URL: ivdon.ru/magazine/archive/n1y2023/8183. (дата обращения: 26.10.2023).
8. El-Mowafy A. On detection of observation faults in the observation and position domains for positioning of intelligent transport systems // Journal of Geodesy. 2019. vol. 93. no. 10. pp. 2109–2122. DOI: 10.1007/s00190-019-01306-1.
9. Zhang Y., Wang L., Xiang Y., Ten C.-W. Power System Reliability Evaluation with SCADA Cybersecurity Considerations // IEEE Transactions on Smart Grid. 2015. vol. 6. no. 4. pp. 1707–1721. DOI: 10.1109/TSG.2015.2396994.
10. Falahati B., Fu Y. Reliability Assessment of Smart Grids Considering Indirect Cyber-Power Interdependencies // IEEE Transactions on Smart Grid. 2014. vol. 5. no. 4. pp. 1677–1685. DOI: 10.1109/TSG.2014.2310742.
11. Falahati B., Fu Y., Wu L. Reliability Assessment of Smart Grid Considering Direct Cyber-Power Interdependencies // IEEE Transactions on Smart Grid. 2012. vol. 3. no. 3. pp. 1515–1524. DOI: 10.1109/TSG.2012.2194520.
12. Haring I., Ebenhoch S., Stolz A. Quantifying Resilience for Resilience Engineering of Socj Technical Systems // European Journal for Security Research. 2016. vol. 1. pp. 21–58. DOI: 10.1007/s41125-015-0001-x.
13. Brauner F., Claben M., Fiedrich F. Competence as Enabler of Urban Critical Infrastructure Resilience Assessment // Urban Disaster Resilience and Security: Addressing Risks in Societies. 2018. pp. 171–184. DOI: 10.1007/978-3-319-68606-6_11.
14. Грудинин И.В., Суровикин С.В. Управление ресурсами информационно-управляющей подсистемы АСУ огнем в интересах обеспечения ее живучести // Известия Института инженерной физики. 2016. № 3(41). С. 57–62.
15. Pashintsev V.P., Chipigs A.F., Koval S.A., Skorik A.D. Analytical method for determining the interval of spatial correlation of fading in single-beam decameter radio line // Telecommunications and Radio Engineering. 2021. vol. 80. no. 2. pp. 89–104. DOI: 10.1615/TelecomRadEng.2021038432.
16. Савищенко Н.В. Остроумов О.А. Расчет оптимального и рационального числа ветвей разнесения в каналах связи с аддитивным белым гауссовым шумом и общими замираниями Райса-Накагами // Информационно-управляющие системы. 2015. № 6(79). С. 71–80. DOI: 10.15217/issn1684-8853.2015.6.71.
17. Петренко С.А. Концепция поддержания работоспособности киберсистем в условиях информационно-технических воздействий // Труды ИСА РАН. 2009. Т. 41. С. 175–193.
18. Kotenko I., Saenko I., Lautu O., Karpov M. Methodology for management of the protection system of smart power supply networks in the context of cyberattacks // Energies. 2021. vol. 14(18). no. 5963. DOI: 10.3390/en14185963.

19. Haque M.A., Shetty S., Krishnappa B. ICS-CRAT: A Cyber Resilience Assessment Tool for Industrial Control Systems. IEEE 5th Intl Conference on Big Data Security on Cloud (BigDataSecurity), IEEE Intl Conference on High Performance and Smart Computing, (HPSC) and IEEE Intl Conference on Intelligent Data and Security (IDS). 2019. pp. 273–281. DOI: 10.1109/BigDataSecurity-HPSC-IDS.2019.00058.
20. Haque M.A., De Teyou G.K., Shetty S., Krishnappa B. Cyber Resilience Framework for Industrial Control Systems: Concepts, Metrics, and Insights, IEEE International Conference on Intelligence and Security Informatics (ISI). 2018. pp. 25–30. DOI: 10.1109/ISI.2018.8587398.
21. Zhu Q. Multilayer Cyber-Physical Security and Resilience for Smart Grid // Smart Grid Control, Power Electronics and Power Systems. 2019. pp. 225–239. DOI: 10.1007/978-3-319-98310-3_14.
22. Kete N., Punzo G., Linkov I. Enhancing resilience within and between critical infrastructure systems // Environment Systems and Decisions. 2018. vol. 38. pp. 275–277. DOI: 10.1007/s10669-018-9706-5.
23. Alsubaie A., Alutaibi K., Marti J. Resilience Assessment of Interdependent Critical Infrastructure // Critical Information Infrastructures Security: 10th International Conference, CRITIS. 2016. pp. 43–55. DOI: 10.1007/978-3-319-33331-1_4.
24. Bologna S., Fasani A., Martellini M. Cyber Security and Resilience of Industrial Control Systems and Critical Infrastructures // Cyber Security: Deterrence and IT protection for critical infrastructures. Cham: Springer International Publishing, 2013. pp. 57–72.
25. Hammad A.W.A., Haddad A. Infrastructure Resilience: Assessment, Challenges and Insights // Industry, Innovation and Infrastructure. Encyclopedia of the UN Sustainable Development Goals. Springer. Cham, 2021. pp. 1–13. DOI: 10.1007/978-3-319-71059-4_25-1.
26. Saaty T.L. Relative measurement and its generalization in decision making why pairwise comparisons are central in mathematics for the measurement of intangible factors the analytic hierarchy/network process // RACSAM-Revista de la Real Academia de Ciencias Exactas, Físicas y Naturales. SerieA. Matematicas. 2008. vol. 102. pp. 251–318.
27. Бородакий Ю.В., Тарасов А.А. О Функциональной устойчивости информационно-вычислительных систем // Известия ЮФУ. Технические науки. 2006. Т. 62. № 7. С. 5–12.
28. Богатырев В.А. К повышению надежности вычислительных систем на основе динамического распределения функций // Изв. Вузов СССР. Приборостроение. 1981. Т. 24. № 8. С. 62–65.
29. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. The Probability of Timely Redundant Service in a Two-Level Cluster of a Flow of Requests that is Heterogeneous in Functionality and Allowable Delays // International Conference on Distributed Computer and Communication Networks. Cham: Springer Nature Switzerland, 2022. pp. 122–134.
30. Турута Е.Н. Организация распределения задач в вычислительных системах, обеспечивающая их отказоустойчивость // Автоматика и вычислительная техника. 1985. № 1. С. 5–14.
31. Турута Е.Н. Обеспечение отказоустойчивости многопроцессорных систем путем перераспределения задач отказавших модулей // Системы управления информационных сетей. М.: Наука, 1983. С. 187–198.
32. Машков О.А., Гостев В.И., Машков В.А. Межмодульный обмен диагностической информацией при самодиагностировании сложных систем // Кибернетика и вычислительная техника. 1996. № 105. С. 108–118.

33. Королев А.Н. Функциональная устойчивость навигационно-информационных систем // Известия вузов. Приборостроение. 2018. Т. 61. № 7. С. 559–565. DOI: 10.17586/0021-3454-2018-61-7-559-565.
34. Портенко Н.И., Скороход А.В., Шуренко В.М. Марковские процессы // Итог науки и техники. Современные проблемы математики. Фундаментальные направления. 1989. Т. 46. С. 5–245.
35. Кузьмич А.А., Лепешкин О.М., Пермяков А.С. Модель функционирования системы телекоммуникационной связи в условиях информационного противоборства // Радиолокация, навигация, связь: Сборник трудов XXVIII Международной научно-технической конференции, посвященной памяти Б.Я. Осипова (г. Воронеж, 27-29 сентября 2022): в 6 т. Воронеж: Издательский дом ВГУ, 2022. С. 203–211.
36. Вержбицкий В.М. Численные методы (математический анализ и обыкновенные дифференциальные уравнения): Учеб. пособие для вузов. М.: Высш. шк., 2001. 382 с.
37. Иванов И.И. Модель функционирования распределенных информационных систем при использовании маскированных каналов связи // Системы управления, связи и безопасности. 2020. № 1. С. 198–234. DOI: 10.24411/2410-9916-2020-10107.
38. Тихонов В.И., Миронов М.А. Марковские процессы. М.: Сов. Радио, 1977. 488 с.

Лепешкин Олег Михайлович — д-р техн. наук, доцент кафедры, кафедра «безопасности инфотелекоммуникационных систем специального назначения», Военная орден Жукова и Ленина краснознаменная академия связи имени С.М. Буденного (ВАС). Область научных интересов: безопасность сетей связи, безопасность социотехнических систем, защита информации. Число научных публикаций — 158. lereshkin1@yandex.ru; Тихорецкий проспект, 3, 194064, Санкт-Петербург, Россия; р.т.: +7(812)247-9832.

Остроумов Олег Александрович — канд. техн. наук, докторант кафедры, кафедра «безопасности инфотелекоммуникационных систем специального назначения», Военная орден Жукова и Ленина краснознаменная академия связи имени С.М. Буденного (ВАС). Область научных интересов: криптографическая защита информации, передаваемой по открытым каналам связи, обеспечение безопасности критически важных объектов систем связи и управления. Число научных публикаций — 134. oleg-26stav@mail.ru; Тихорецкий проспект, 3, 194064, Санкт-Петербург, Россия; р.т.: +7(812)247-9832.

Михайличенко Николай Валерьевич — канд. техн. наук, доцент кафедры, кафедра «программной инженерии и вычислительной техники», Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруневича (СПбГУТ). Область научных интересов: автоматизированные системы управления, построение центров обработки данных. Число научных публикаций — 69. 23esn2008@ Rambler.ru; Тихорецкий проспект, 3, 194064, Санкт-Петербург, Россия; р.т.: +79111758475.

Пермяков Александр Сергеевич — канд. техн. наук, доцент кафедры, кафедра «безопасности инфотелекоммуникационных систем специального назначения», Военная орден Жукова и Ленина краснознаменная академия связи имени С.М. Буденного (ВАС). Область научных интересов: защита систем и сетей связи. Число научных публикаций — 56. Permyak.as@ya.ru; Тихорецкий проспект, 3, 194064, Санкт-Петербург, Россия; р.т.: +7(812)247-9832.

O. LEPESHKIN, O. OSTROUMOV, N. MIKHAILICHENKO, A. PERMYAKOV
**A METHOD FOR ENSURING THE FUNCTIONAL STABILITY OF
A COMMUNICATION SYSTEM BY DETECTING CONFLICTS**

Lepeshkin O., Ostroumov O., Mikhailichenko N., Permyakov A. A Method for Ensuring the Functional Stability of a Communication System by Detecting Conflicts.

Abstract. Introduction: Modern complex technical systems are often critical. Criticality is due to the consequences of disruption of the functioning of such systems, and their failure to fulfill the required list of functions and tasks. The process of control and management of such systems is carried out using communication systems and networks that become critical for them. There is a need to ensure the stable functioning of the complex technical systems themselves, their control and monitoring systems, communication systems and networks. The paper proposes a method for ensuring the functional stability of a communication system, the basis of which is the process of identifying and eliminating conflicts in it due to the difference between the profile of functioning and the profile of the process of functioning of the system. The proposed model of the process of functioning of the communication system allows, based on changes in the intensity of the impact on the system of destabilizing factors, the identification of conflicts and their elimination, to determine the probability of ensuring the functional stability of the system. The purpose of the study: to develop a methodology for ensuring the functional stability of a communication system under the influence of destabilizing factors and the emergence of conflicts, a model of the process of the system's functioning, which makes it possible to determine the probability of the system being in a functionally stable state. Methods of graph theory and matrix theory, the theory of Markov processes. Results: an approach is proposed for assessing the functional stability of a communication system under the influence of destabilizing factors, a technique has been developed to ensure the functional stability of a communication system. Practical significance: the results of the study can be used in the design and construction of complex technical systems, decision support systems, control, communication and management.

Keywords: functional stability, criticality, communication system, control system, complex technical system, system functioning profile, functions, tasks, regulations.

References

1. Kondrashov Yu.V., Satdinov A.I., Sinyuk A.D., Ostroumov O.A. [A conceptual model for monitoring the functions of a communication system for identifying conflict situations]. T-Comm – Telekommunikacii i transport – T-Comm – Telecommunications and transport. 2022. vol. 16. no. 5. pp. 21–27. DOI: 10.36724/2072-8735-2022-16-5-21-27. (In Russ.).
2. Makarenko S.I. Modeli sistemy svyazi v usloviyah prednamerennyh destabilizirujushhijh vozdeystvij i vedenija razvedki. Monografiya [Models of communication systems in conditions of deliberate destabilizing impacts and intelligence. Monograph]. St. Petersburg: Naukoemkie Tehnologii Publ., 2020. 337 p. (In Russ.).
3. Ostroumov O.A. [The problem of ensuring the functional stability of systems of critical facilities]. Elektrosvyaz– Telecommunications. 2022. no. 1. pp. 38–42. DOI: 10.34832/ELSV.2022.26.1.005. (In Russ.).
4. Tarasov A.A. Funktsional'naya rekonfiguratsiya otkazoustoychivykh sistem: monografiya [Functional reconfiguration of fault-tolerant systems: monograph]. Moscow: Logos, 2012. 152 p. (In Russ.).

5. Starodubtsev Yu.I., Zakalkin P.V., Ivanov S.A. [Technospheric warfare as the main way to resolve conflicts in the context of globalization]. *Voenaya misl' – Military Thought*. 2020. no. 10. pp. 16–21. (In Russ.).
6. Ostroumov O.A. A model for monitoring the functioning of a communication system. *Izvestiya Tul'skogo gosudarstvennogo universiteta. Tekhnicheskiye nauki – News of the Tula State University. Technical Sciences*. 2022. no. 3. pp. 300–309. (In Russ.).
7. Lauta O.S., Balenko E.G., Fedorov V.Kh., Lepeshkin O.M., Ostroumov O.A. [A method for constructing a profile of the functioning of a complex technical system]. *Inzhenernyj vestnik Dona – Don Engineering Bulletin*. 2023. no. 2(98). pp. 48–77. Available at: ivdon.ru/magazine/archive/n1y2023/8183. (accessed 26.10.2023). (In Russ.).
8. El-Mowafy A. On detection of observation faults in the observation and position domains for positioning of intelligent transport systems. *Journal of Geodesy*. 2019. vol. 93. no. 10. pp. 2109–2122. DOI: 10.1007/s00190-019-01306-1.
9. Zhang Y., Wang L., Xiang Y., Ten C.-W. Power System Reliability Evaluation with SCADA Cybersecurity Considerations. *IEEE Transactions on Smart Grid*. 2015. vol. 6. no. 4. pp. 1707–1721. DOI: 10.1109/TSG.2015.2396994.
10. Falahati B., Fu Y. Reliability Assessment of Smart Grids Considering Indirect Cyber-Power Interdependencies. *IEEE Transactions on Smart Grid*. 2014. vol. 5. no. 4. pp. 1677–1685. DOI: 10.1109/TSG.2014.2310742.
11. Falahati B., Fu Y., Wu L. Reliability Assessment of Smart Grid Considering Direct Cyber-Power Interdependencies. *IEEE Transactions on Smart Grid*. 2012. vol. 3. no. 3. pp. 1515–1524. DOI: 10.1109/TSG.2012.2194520.
12. Haring I., Ebenhoch S., Stolz A. Quantifying Resilience for Resilience Engineering of Socij Technical Systems. *European Journal for Security Research*. 2016. vol. 1. pp. 21–58. DOI: 10.1007/s41125-015-0001-x.
13. Brauner F., Claben M., Fiedrich F. Competence as Enabler of Urban Critical Infrastructure Resilience Assessment. *Urban Disaster Resilience and Security: Addressing Risks in Societies*. 2018. pp. 171–184. DOI: 10.1007/978-3-319-68606-6_11.
14. Grudinin I.V., Surovkin S.V. [Resource management of the information and control subsystem of the ACS by fire in the interests of ensuring its survivability]. *Izvestiya Instituta inzhenernoy fiziki– Bulletin of the Institute of Engineering Physics*. 2016. no. 3(41). pp. 57–62. (In Russ.).
15. Pashintsev V.P., Chipigs A.F., Koval S.A., Skorik A.D. Analytical method for determining the interval of spatial correlation of fading in single-beam decimeter radio line. *Telecommunications and Radio Engineering*. 2021. vol. 80. no. 2. pp. 89–104. DOI: 10.1615/TelecomRadEng.2021038432.
16. Savishchenko N.V. Ostroumov O.A. [Calculation of the optimal and rational number of diversity branches in communication channels with additive white Gaussian noise and common Rice-Nakagami fading]. *Informatsionno-upravliaiushchie sistemy – Information and control systems*. no. 6(79). 2015. pp. 71–80. DOI: 10.15217/issn1684-8853.2015.6.71. (In Russ.).
17. Petrenko S.A. [The concept of maintaining the efficiency of cyber systems under conditions of information and technical impacts]. *Trudy Instituta sistemnogo analiza Rossiyskoy akademii nauk – Proceedings of the Institute for System Analysis of the Russian Academy of Sciences*. 2009. vol. 41. pp. 175–193. (In Russ.).
18. Kotenko I., Saenko I., Lauta O., Karpov M. Methodology for management of the protection system of smart power supply networks in the context of cyberattacks. *Energies*. 2021. vol. 14(18). no. 5963. DOI: 10.3390/en14185963.
19. Haque M.A., Shetty S., Krishnappa B. ICS-CRAT: A Cyber Resilience Assessment Tool for Industrial Control Systems. *IEEE 5th Intl Conference on Big Data Security*

- on Cloud (BigDataSecurity), IEEE Intl Conference on High Performance and Smart Computing, (HPSC) and IEEE Intl Conference on Intelligent Data and Security (IDS). 2019. pp. 273–281. DOI: 10.1109/BigDataSecurity-HPSC-IDS.2019.00058.
20. Haque M.A., De Teyou G.K., Shetty S. Krishnappa B. Cyber Resilience Framework for Industrial Control Systems: Concepts, Metrics, and Insights, IEEE International Conference on Intelligence and Security Informatics (ISI). 2018. pp. 25–30. DOI: 10.1109/ISI.2018.8587398.
 21. Zhu Q. Multilayer Cyber-Physical Security and Resilience for Smart Grid. Smart Grid Control, Power Electronics and Power Systems. 2019. pp. 225–239. DOI: 10.1007/978-3-319-98310-3_14.
 22. Kete N., Punzo G., Linkov I. Enhancing resilience within and between critical infrastructure systems. Environment Systems and Decisions. 2018. vol. 38. pp. 275–277. DOI: 10.1007/s10669-018-9706-5.
 23. Alsubaie A., Alutaibi K., Marti J. Resilience Assessment of Interdependent Critical Infrastructure. Critical Information Infrastructures Security: 10th International Conference, CRITIS. 2016. pp. 43–55. DOI: 10.1007/978-3-319-33331-1_4.
 24. Bologna S., Fasani A., Martellini M. Cyber Security and Resilience of Industrial Control Systems and Critical Infrastructures. Cyber Security: Deterrence and IT protection for critical infrastructures. Cham: Springer International Publishing, 2013. pp. 57–72.
 25. Hammad A.W.A., Haddad A. Infrastructure Resilience: Assessment, Challenges and Insights. Industry, Innovation and Infrastructure. Encyclopedia of the UN Sustainable Development Goals. Springer. Cham, 2021. pp. 1–13. DOI: 10.1007/978-3-319-71059-4_25-1.
 26. Saaty T.L. Relative measurement and its generalization in decision making why pairwise comparisons are central in mathematics for the measurement of intangible factors the analytic hierarchy/network process. RACSAM-Revista de la Real Academia de Ciencias Exactas, Fisicas y Naturales. Serie A. Matematicas. 2008. vol. 102. pp. 251–318.
 27. Borodaki Yu.V., Tarasov A.A. [On the Functional Stability of Information and Computing Systems]. Izvestiya YUFU. Tekhnicheskie nauki – Izvestiya SFedU. Technical science. 2006. vol. 62. no. 7. pp. 5–12. (In Russ.).
 28. Bogatyrev V.A. [To increase the reliability of computing systems based on the dynamic distribution of functions]. Izvestiya Vuzov SSSR. Priborostroenie – Izvestiya Vuzov USSR. Instrumentation. 1981. vol. 24. no. 8. pp. 62–65. (In Russ.).
 29. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. The Probability of Timely Redundant Service in a Two-Level Cluster of a Flow of Requests that is Heterogeneous in Functionality and Allowable Delays. International Conference on Distributed Computer and Communication Networks. Cham: Springer Nature Switzerland, 2022. pp. 122–134.
 30. Turuta E.N. [Organization of task distribution in computing systems, ensuring their fault tolerance]. Avtomatika i vychislitel'naya tekhnika – Automation and Computer Science. 1985. no. 1. pp. 5–14. (In Russ.).
 31. Turuta E.N. [Ensuring the fault tolerance of multiprocessor systems by redistributing the tasks of failed modules]. Sistemy upravleniya informacionnyh setej – Control systems of information networks. M.: Nauka, 1983. pp. 187–198. (In Russ.).
 32. Mashkov O.A., Gostev V.I., Mashkov V.A. [Intermodule exchange of diagnostic information during self-diagnosis of complex systems]. Kibernetika i vychislitel'naya tekhnika – Cybernetics and Computer Science. 1996. no. 105. pp. 108–118. (In Russ.).
 33. Korolev A.N. [Functional stability of navigation and information systems]. Izvestiya vuzov. Priborostroenie – Izvestiya vuzov. Instrumentation. 2018. vol. 61. no. 7. pp. 559–565. DOI: 10.17586/0021-3454-2018-61-7-559-565. (In Russ.).

34. Portenko N.I., Skorokhod A.V., Shurenko V.M. [Markov processes]. Itog nauki i tehniki. Sovremennyye problemy matematiki. Fundamental'nye napravleniya – Results of science and technology. Modern problems of mathematics. Fundamental directions. 1989. vol. 46. pp. 5–245. (In Russ.).
35. Kuzmich A.A., Lepeshkin O.M., Permyakov A.S. [Model of functioning of the telecommunication system in the conditions of information confrontation] // Radiolokatsiya, navigatsiya, svyaz': Sborniktrudov XXVIII Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii, posvyashchennoy pamyati B.Ya. Osipova [Radar, navigation, communication: Proceedings of the XXVIII International scientific and technical conference dedicated to the memory of B.Ya. Osipov]. Voronezh: VSU Publishing House, 2022. pp. 203–211. (In Russ.).
36. Verzhbitsky V.M. Chislennyye metody (matematicheskiy analiz i obyknovennyye differentsial'nyye uravneniya): Ucheb. posobiye dlya vuzov [Numerical methods (mathematical analysis and ordinary differential equations): Proc. allowance for universities]. Moscow: Vysshaya shkola, 2001. 382 p. (In Russ.).
37. Ivanov I.I. [Model of functioning of distributed information systems when using masked communication channels]. Sistemy upravleniya, svyazi i bezopasnosti – Systems of Control, Communication and Security. 2020. no. 1. pp. 198–234. DOI: 10.24411/2410-9916-2020-10107. (In Russ.).
38. Tikhonov V.I., Mironov M.A. Markovskiye protsessy [Markov processes]. Moscow: Sov. Radio, 1977. 488 p. (In Russ.).

Lepeshkin Oleg — Ph.D., Dr.Sci., Associate professor of the department, Department protection of information and telecommunication systems for special purposes, Military Orders of Zhukov and Lenin Red Banner Academy of Communications named after S.M. Budyonny (VAS). Research interests: security of communication networks, security of sociotechnical systems, information protection. The number of publications — 158. lepechkin1@yandex.ru; 3, Tikhoretsky Av., 194064, St. Petersburg, Russia; office phone: +7(812)247-9832.

Ostroumov Oleg — Ph.D., Doctoral student of the department, Department protection of information and telecommunication systems for special purposes, Military Orders of Zhukov and Lenin Red Banner Academy of Communications named after S.M. Budyonny (VAS). Research interests: cryptographic protection of information transmitted through open communication channels, ensuring the security of communication and control systems critical objects. The number of publications — 134. oleg-26stav@mail.ru; 3, Tikhoretsky Av., 194064, St. Petersburg, Russia; office phone: +7(812)247-9832.

Mikhailichenko Nikolay — Ph.D., Associate professor of the department, Department of software engineering and computer science, St. Petersburg State University of Telecommunications. prof. M.A. Bonch-Brunevich (SPbSUT). Research interests: automated control systems, building data centers. The number of publications — 69. 23esn2008@rambler.ru; 3, Tikhoretsky Av., 194064, St. Petersburg, Russia; office phone: +79111758475.

Permyakov Alexander — Ph.D., Associate professor of the department, Department protection of information and telecommunication systems for special purposes, Military Orders of Zhukov and Lenin Red Banner Academy of Communications named after S.M. Budyonny (VAS). Research interests: protection of communication systems and networks. The number of publications — 56. Permyak.as@ya.ru; 3, Tikhoretsky Av., 194064, St. Petersburg, Russia; office phone: +7(812)247-9832.

S. QIUSHI, H. YANG, O. PETROSIAN
**GRAPH ATTENTION NETWORK ENHANCED POWER
ALLOCATION FOR WIRELESS CELLULAR SYSTEM**

Qiushi S., Yang H., Petrosian O. **Graph Attention Network Enhanced Power Allocation for Wireless Cellular System.**

Abstract. The importance of an efficient network resource allocation strategy has grown significantly with the rapid advancement of cellular network technology and the widespread use of mobile devices. Efficient resource allocation is crucial for enhancing user services and optimizing network performance. The primary objective is to optimize the power distribution method to maximize the total aggregate rate for all customers within the network. In recent years, graph-based deep learning approaches have shown great promise in addressing the challenge of network resource allocation. Graph neural networks (GNNs) have particularly excelled in handling graph-structured data, benefiting from the inherent topological characteristics of mobile networks. However, many of these methodologies tend to focus predominantly on node characteristics during the learning phase, occasionally overlooking or oversimplifying the importance of edge attributes, which are equally vital as nodes in network modeling. To tackle this limitation, we introduce a novel framework known as the Heterogeneous Edge Feature Enhanced Graph Attention Network (HEGAT). This framework establishes a direct connection between the evolving network topology and the optimal power distribution strategy throughout the learning process. Our proposed HEGAT approach exhibits improved performance and demonstrates significant generalization capabilities, as evidenced by extensive simulation results.

Keywords: MISO, cellular network, edge-feature, graph attention network, power allocation.

1. Introduction. In recent years, significant advancements have been witnessed in the technology employed for data transmission inside wireless networks. The contemporary landscape exhibits a smooth amalgamation of diverse mobile terminals within these networks, including cell phones and wearable gadgets. Consequently, this integration has resulted in a substantial surge in the number of simultaneous users. As a result, the cellular network's topography has witnessed a rise in the concentration of User Equipments (UEs) in highly populated areas, accompanied by a simultaneous reduction in cell size. The cellular environment is now experiencing a significant increase in wireless transmissions due to this phenomenon. The interference problem has become notably apparent as a direct result, manifesting inside individual cells and across cell boundaries. Due to the intricate nature of the circumstances, implementing strategies for interference management and rational power control has increased significance. These strategies mitigate any interference among users and enhance the network's overall efficiency. The gravity of this subject has engendered significant scholarly attention, leading to robust research endeavors to discover more efficacious solutions.

Considerable research endeavors have been devoted to formulating power allocation algorithms for cellular networks, whereas conventional methodologies frequently depend on numerical modeling methodologies. Decentralized and centralized optimization approaches have been prominent in power distribution in cellular networks, primarily due to the intrinsic complexity of this task, which is categorized as an NP-hard problem [1]. Using numerical simulation techniques requires a sequence of repetitive calculations using both implicit and explicit approaches. Noteworthy examples include genetic algorithms (GA), weighted minimum mean square error (WMMSE) [2], fractional programming (FP) [3], branch-and-bound techniques [4], and heuristic algorithms [5]. However, in scenarios involving large-scale networks, these iterative methods often come with extended computational time, rendering them unsuitable for real-time resource allocation. This limitation stems from the rapid fluctuations in the wireless channel's state, which can occur within a brief time span of milliseconds.

Several researchers have proposed the application of deep learning (DL) techniques as an innovative approach to power distribution, including supervised learning methods [6-8]. In contrast to traditional iterative methods, Convolutional Neural Networks (CNNs) and Multi-Layer Perceptrons (MLPs) have emerged as prominent architectural choices for capturing the underlying mapping functions in power control [9]. Once adequately trained, artificial neural networks can efficiently deduce solutions for various scenarios through feed-forward computations. However, it's crucial to recognize that the use of data-driven learning approaches necessitates the development of a benchmark algorithm for training, which can impose constraints on the resulting model's effectiveness. Additionally, while CNN- and MLP-based approaches offer rapid inference capabilities, they may not fully leverage the network's topological characteristics, which could require substantial training data and potentially limit their efficacy.

There have been proposals for GNN-based methodologies aimed at tackling the difficulties above. GNN can collect spatial information that is concealed inside the network topology. Moreover, they can extend this knowledge to other topologies, particularly in dynamic scenarios. The existing body of research demonstrates the efficacy of GNN-based approaches in addressing diverse challenges across various network contexts. The graph convolutional network (GCN) architecture is used to get close to the UWMMSE solution for the power allocation problem in the interference channel [10]. The power allocation technique, developed using GCN, aims to determine the best way to allocate resources in Federated Learning (FL) activities that take place in wireless networks with interference restrictions [11]. Interference

GCN (IGCNet) is introduced as a novel approach for addressing the power control problem in K-user interference channels [12]. In contrast to the conventional GCN, the model learning process is contingent upon incorporating the structural information neighborhood matrix encompassing the entirety of the graph. The Graph Attention Network (GAT) is a neural network model incorporating the widely used attention mechanism to calculate the weights between nodes in a graph [13]. This approach involves utilizing the feature representation of nodes rather than depending just on the structural information of the network, hence facilitating inductive learning for weight computation between nodes.

While previous studies have successfully designed homogeneous or heterogeneous GNNs, these designs have primarily focused on the node update mechanism, often overlooking the valuable information contained within edge characteristics. In conventional research, each transceiver pair in cellular networks has typically been represented as an individual node, with the channel state information of the direct communication connection serving as the corresponding node characteristic. The connections that disrupt communication between various pairs of transceivers are depicted as edges in the model, with the channel state information associated with each edge considered as the relevant edge feature [1]. To address the limitations outlined above, this study introduces the HEGAT framework as a potential solution for multiplexing the downlink of cellular users in Long-Term Evolution (LTE) systems. The primary contributions of this paper are as follows:

- We provide a comprehensive methodology for addressing power control challenges in cellular networks using heterogeneous graph topologies. In this theoretical framework, the communication links originating from the base station and connecting to user equipment are represented as vertices. In contrast, the interference links between different pairs of transceivers are denoted as edges. It's important to note that every node within the cellular network exhibits isomorphism, ensuring fair treatment. However, edges are categorized into two distinct types: intra-cell and inter-cell interference.

- We introduce an innovative method to enhance feature properties. It's crucial to highlight that the optimization of unknown variables primarily occurs within nodes. Consequently, when updating node features, we intentionally give due consideration to the attributes and classifications of the neighboring edges. This approach allows us to extract information from these two sets of adjacent edges using distinct methodologies. Building upon the edge feature enhancement technique, we propose the introduction of a neural network architecture named HEGAT. This architectural design exhibits a high degree

of effectiveness in mapping graph characteristics to node variables, thereby achieving the power allocation objective.

– The simulation results illustrate the effectiveness of the HEGAT approach in addressing power allocation challenges within cellular networks, particularly in the context of power distribution in interference channels. Comparative trials further substantiate that the proposed HEGAT surpasses existing state-of-the-art methods in terms of achieving higher sum rates. Moreover, HEGAT consistently delivers strong performance across a wide range of scenarios, encompassing varying numbers of BSs and UEs, diverse network characteristics, and different transmit power budgets.

The remainder of the paper is organized as follows. Section 2 introduces the related work. Section 3 presents the mathematical formulation of the power allocation problem in wireless cellular networks. Section 4 offers an exhaustive elucidation of the graph representation of the network, alongside a detailed exposition of our novel HEGAT algorithm. Section 5 presents the analytical simulation outcomes. Section 6 presents the discussion and conclusions.

2. Related Works

2.1. Edge Enhanced Graph. GNNs have demonstrated strong learning capabilities in tackling challenges associated with graph structures. The need to effectively handle edge information is prevalent in real-world scenarios. Message-passing neural networks (MPNNs) encompass several distinct stages, including message-passing and readout phases. Integral to this paradigm is the incorporation of node attributes. In parallel, the utilization of edge attributes for network characterization is also prevalent, and a technique has been proposed for updating these attributes to predict node features. While MPNNs incorporate edge information during the message-passing phase, their message-passing mechanism lacks the ability to capture knowledge about the topological relationships between nodes and edges. Relational Graph Convolution Networks (RGCN) employ forward-passing rules to enhance the weight matrix with additional edge-related weights [14]. However, empirical studies have shown that computing this simple aggregation doesn't significantly improve performance. Instead, the Edge Feature Graph Neural Network (EGNN) employs an aggregation function to combine node information while training separate attention weights for each feature dimension [15]. But this method may result in the loss of peripheral information. The Convolution with Edge-Node Switching Graph Neural Network (CensNet) utilizes a line graph structure to create an auxiliary graph [16]. This approach involves training the model on both the original graph and the line graph, allowing for the updating of node and edge embeddings. However, using an approximate spectrogram convolution during layer-by-layer propagation renders CensNet

inept in managing extensive directed graphs. Consequently, it is unsuited for wireless networks that are represented as directed graphs

2.2. Heterogenous Networks. Although homogeneous graphs have shown to be highly effective in radio network power control problems involving only one kind of node or edge, it is important to acknowledge that most scenarios are characterized by a diverse range of node and edge types [17]. Heterogeneous graphs have been found to be more advantageous than homogeneous graphs in addressing intricate radio resource management challenges. The Heterogeneous Interference Graph Neural Network (HIGNN) is specifically developed to effectively address diverse network scenarios characterized by heterogeneity [18]. The nodes in the communication network of Device-to-Device (D2D) connections are categorized based on the number of antennas present on the transmitters inside their respective links. The allocation of power is employed in D2D downlink systems. The introduction of the Heterogeneous Ultra-Dense Network (HUDN) aims to address the challenge of resource allocation in communication situations that involve a combination of D2D networks and cellular networks [19]. The communication linkages are considered as nodes, which are classified based on the sorts of devices they establish connections with. The introduction of Heterogeneous Graph Neural Network (HetGNN) aims to explore the Power Allocation strategy in Multi-Cell-Multi-User Systems [20]. The nodes in the network diagram represent the entities BS and UE, while the edges reflect the communication links between them.

One common characteristic seen in the aforementioned publications is their primary emphasis on the weights of edges, while neglecting the differences that arise from different types of edges. However, the focus of these studies is on the incorporation of different node types inside the framework of GNN. In contrast, the present study adopts a divergent methodology. The cellular network is represented as a directed graph, with a distinction made between two types of interfering links: intra-cell and inter-cell. In order to examine the various sorts of edges, we employ the HEGAT architecture. This architectural design is very suitable for effectively capturing and acquiring the intrinsic characteristics of edges, comprising both their properties and classifications.

2.3. Material and Methods. In this subsection we introduce the basic concepts related to resource allocation. MISO (Multiple-Input Single-Output): The MISO cellular network is a wireless communication technology that is employed in cellular networks and several other wireless applications. In a MISO system, the base station or access point is equipped with multiple transmit antennas (inputs), while the user's device, commonly referred to as the UE, is equipped with a single receive antenna (output). One notable attribute

of a MISO system is its capability to enable the base station to concurrently broadcast numerous data streams to a single user equipment, effectively using the spatial diversity offered by the multiple transmit antennas. The presence of spatial diversity has the potential to enhance the dependability and efficiency of wireless communication links, particularly in settings characterized by interference or signal fading. The utilization of MISO technology is prevalent in diverse wireless communication protocols, such as 4G LTE (Long-Term Evolution) and 5G, with the objective of augmenting the capacity and quality of wireless connections.

The Graph Neural Network (GNN): It is an innovative neural network structure capable of inferring the interdependencies between nodes in a graph utilizing propagating messages among the nodes. Hence, GNN have demonstrated their efficacy in tackling the learning task by employing a graphical structure, whereby each vertex incorporates feature information from neighboring vertices to derive a hidden state embedding based on graph perception. In practice, the hidden state embedding of each node is repeatedly updated by aggregating state information from its neighboring nodes. This study employs GNN to model the subnetwork system as a dynamic graph. Next, a two-stage attention method is employed to streamline the graph and identify the probable interference link across subnetworks across different dimensions.

3. System Model And Graph Representation

3.1. System Model. We consider a classical scenario of downlink multicell communication, a massive MISO network with M -antennas BSs and single-antenna UEs. The PA problem in the cellular network is with the setting of interfering multiple-access channels (IMAC) [21]. All BSs within the network coverage area simultaneously serve all UEs. However, since different cells use the same frequency, the UEs are still subject to inter-cell and intra-cell interference. Index the BSs as $\mathcal{N} = \{1, \dots, N\}$ and UEs as $\mathcal{K} = \{1, \dots, K\}$. Denote D_{nk} as the set of k -th UE's neighbour UEs in the n -th cell, denote C_n as the set of n -th cell's neighbour cells. Assume that $n \in \mathcal{N}$, $k \in \mathcal{K}$, $k' \in D_{nk}$, $n' \in C_n$, then the received signal of the k -th UE from n -th BS in n -th cell can be formulated by:

$$\begin{aligned}
 y_{nk} = & \underbrace{g_{n,nk}^H w_{nk} \sqrt{p_{nk}} s_{nk}}_{\text{desired signal}} + \underbrace{\sum_{k' \neq k} g_{n,nk}^H w_{nk'} \sqrt{p_{nk'}} s_{nk'}}_{\text{intra-cell interference}} \\
 & + \underbrace{\sum_{n' \neq n} \sum_{k'} g_{n',nk}^H w_{n'k'} \sqrt{p_{n'k'}} s_{n'k'}}_{\text{inter-cell interference}} + z_{nk}, \tag{1}
 \end{aligned}$$

where $g_{n,nk}$ denote the the channel response from n -th BS to k -th UE in n -th cell, p_{nk} denotes the corresponding transmit power. $s_{nk} \sim \mathcal{U}(0, 1)$ is the transmit signal. $z_{nk} \sim \mathcal{N}(0, \sigma^2)$ is the additive white Gaussian noise (AWGN). The coordinated beamforming (CB) vector from n -th BS to k -th UE is denoted as w_{nk} . The literature on Coordinated Multi-Point (CoMP) CB has explored multiple schemes. In this study, we have opted to utilize the zero-forcing beamforming scheme [22] to simplify the problem. Then the signal-to-interference-plus-noise ratio (SINR) of k -th UE can be calculated as:

$$\gamma_{nk} = \frac{g_{nk,nk} p_{nk}}{\sum_{k' \neq k} g_{nk,nk'} p_{nk'} + \sum_{n' \neq n} \sum_k g_{nk,n'k'} p_{n'k'} + \sigma^2}, \quad (2)$$

where $g_{nk,nk} = \left| g_{n,nk}^H w_{nk} \right|^2$ denote independent channel gain of the desired signal. $g_{nk,nk'} = \left| g_{n,nk}^H w_{nk'} \right|^2$ denote channel gain of intra-cell interference from neighbour UEs in n -th cell. $g_{nk,n'k'} = \left| g_{n',nk}^H w_{n'k'} \right|^2$ denote channel gain of inter-cell interference from neighbour UEs in n -th cell's adjacent cells.

The downlink rate of communication link nk can be expressed in terms of normalized bandwidth as:

$$C_{nk} = \log_2(1 + \gamma_{nk}). \quad (3)$$

The primary aim of this study is to identify the ideal power level that optimizes the overall network sum rate, while adhering to the limitation of a maximum power limit for each transmitter. The provided problem may be expressed as:

$$\begin{aligned} & \max_{p_{nk}, w_{nk}} \sum_{n=1}^N \sum_{k=1}^K \log_2(1 + \gamma_{nk}) \\ & \text{s.t. } 0 \leq p_{nk} \leq p_{\max}, \forall n \in \mathcal{N}, k \in \mathcal{K}. \end{aligned} \quad (4)$$

The objective function presents a challenging obstacle in the form of a nonconvex nonlinear optimization problem, which is further complicated by the presence of constraints. As a result, finding the global optimal solution becomes a complex endeavor [23]. Heuristic algorithms have the capability to approximate solutions that are globally optimum, but at the

cost of substantial computing resources. In order to cater to the demand for real-time applications that require low-complexity solutions, we suggest using deep learning techniques to parameterize these solutions. Although attaining theoretical optimality for learnt solutions may pose challenges, actual evidence continually shows that deep learning methods often produce extremely satisfying performance results.

3.2. Graph Representation. We model the multicell cellular network (Figure 1) as the fully connected weighted directed graph (Figure 2) which can be expressed as $G = (V, E)$. Each BS-to-UE communication link is considered as a node, denoting V as a set of nodes, $V = \{v_{nk}\}, n \in \mathcal{N}, k \in \mathcal{K}$. In contrast, each interfering link is considered as an edge, denoting E as a set of edges, $E = \{e_{nk,ml}\}, n, m \in \mathcal{N}, k, l \in \mathcal{K}, nk \neq ml$. The attributes such as distance, channel information, and weight associated with the communication link are node characteristics. The assigned power is used as the predicted node label. Attributes such as distance and channel information associated with the interfering links are considered edge features. The notations $\phi \rightarrow \mathbb{C}^{d_V}$ and $\psi \rightarrow \mathbb{C}^{d_E}$ represent the mapping of nodes and edges to their respective features, where d_V and d_E represent the dimension of feature space for node and edge, respectively.




Fig. 1. Example of cellular

To train the GAT model, the graph in Figure 2 is used as input, and the iterations of the neural network are used to learn the vector representation of each network.




Fig. 2. Graph representation

4. Heterogenous Edge feature Enhanced Graph Attention Network

4.1. Feature Concate. Prior to integrating neighbor information into the heterogeneous graph, it is crucial to recognize that the connections between neighbors and each node, whether through nodes or edges, may possess distinct functionalities and varying degrees of importance in the task of generating node embeddings for resource allocation [24].

In the context of this work, we propose the utilization of node feature attention in conjunction with the augmentation of edge features. The proposed strategic combination is formulated as an effective approach to carefully evaluate the importance of both node-based and edge-based neighbors. By integrating the attention mechanism, it becomes possible to generate node and edge embeddings, effectively capturing the representations of these significant neighboring entities. This methodology enables us to reveal their unique functions and contributions inside the complex framework of resource allocation procedures [25].

The presence of diverse edges within a network introduces a spectrum of variations in their characteristics. As a result, different types of edges may manifest distinctive properties. These features encompass both attributes and types, where attributes are expressed by continuous and intricate variables, while types are denoted as discrete variables. The attribute of the edge $e_{nk,ml}$ denoted by the vector $e_{nk,ml}^{attr}$, and the type of the edge $e_{nk,ml}$ is denoted by the vector $e_{nk,ml}^{type}$. The features of the edge $e_{nk,ml}$ can be represented as

$e_{nk,ml} = \left[e_{nk,ml}^{attr} \parallel e_{nk,ml}^{type} \right]$, which is obtained by concatenating its transformed node attributes and type information.

4.2. Edge Feature Enhanced Node Attention Layer. In the heterogeneous graph, the definition of node-based neighbors N_{nk} refers to the nodes directly connecting to a particular node v_{nk} . It is essential to acknowledge that the neighbors of a certain node encompass the node itself. Similarly, the edge-based neighbors $E_{nk,ml}$ refers to the set of edge $e_{nk,ml}$ that directly connect to a certain node v_{nk} [26].

As shown in Figure 3, circles represent nodes, and squares represent edges. Take v_{11} for example, the node-based neighbors of node v_{11} are v_{11} , v_{12} , v_{23} , and v_{34} . Note that the node-based neighbors of node v_{11} contain itself; The edge-based neighbors of node v_{11} are $e_{11,12}$, $e_{11,23}$, and $e_{11,34}$.




Fig. 3. Architecture of HEGAT. The model consists of multiple HEGAT layers. Each iteration incorporates the features of the first-order neighbors (nodes and edges) to generate new node features

It is necessary to map these vectors to a high-dimensional space using the GAT layer to enhance the network topology information contained in the original low-dimensional features $n_{nk} = [w_{nk}, p_{nk}, g_{nk, nk}]$ obtained from the network. The input to the GAT network contains a set of node features denoted as $n = (n_{11}, \dots, n_{nk}, \dots, n_{NK}), n_{nk} \in R^{d_v}$, where each n_{nk} is the feature of existing BS-to-UE pair v_{nk} .

Theoretically, GAT can use all nodes other than the central node to calculate the similarity with that central node. The dimensions of the node and edge feature spaces may vary. To enhance the expression of the node features, the layer of parameter-sharing neural networks is added to linearly transform the features (whether for nodes or edges), and the network is denoted by Att_{node} and Att_{edge} . Define $W_n \in \mathbb{R}^{d_v \times d'_v}$ and $W_e \in \mathbb{R}^{d_E \times d'_E}$ as the learnable weight matrix transforming input features linearly into high-level features, the dimension for the feature vector of the node is made to change from d_v to d'_v , the dimension for the feature vector of the edge is made to change from d_E to d'_E . The self-attention mechanism is used to calculate the similarity between the central node and the neighbor nodes, where the similarity is calculated by a layer of the neural network the parameters are denoted by β^T , and the two transformed feature vectors are fed into this network after stitching. The importance coefficient of node v_{ml} to node v_{nk} is expressed as:

$$c_{nk,ml} = Att_{node}(W_n \mathbf{n}_{nk}, W_n \mathbf{n}_{ml}). \quad (5)$$

The importance coefficient of edge $e_{nk,ml}$ to node v_{nk} is expressed as:

$$c_{nk,(nk,ml)} = Att_{edge}(W_n \mathbf{n}_{nk}, W_e \mathbf{e}_{ml}). \quad (6)$$

In this context, we apply the edge feature enhanced attention mechanism to calculate the attention weights associated with the neighbors of each one-degree node and edge. This calculation considers not only the features of the neighboring nodes, but also incorporates the features of the adjacent edges. Throughout this process, the features are jointly combined, with their respective parameters governed by the attention vector β^T and the activation function *LeakyReLU*. The resulting weight which is normalized using the softmax function for node v_{ml} is expressed as:

$$\alpha_{nk,ml} = softmax_{ml}(c_{nk,ml}) = \left(\frac{\exp(\sigma(\beta_n^T [W_n \mathbf{n}_{nk} \| W_n \mathbf{n}_{ml}]))}{\sum_{rs \in \mathcal{N}_j} \exp(\sigma(\beta_n^T [W_n \mathbf{n}_{nk} \| W_n \mathbf{n}_{rs}]))} \right), \quad (7)$$

where $\beta_n^T \in \mathbb{R}^{2d'_v}$ denotes the attention vector for node-based neighbors. The attention mechanism is implemented as a single-layer feedforward neural network, which is characterized by the parameters W and β . This neural network utilizes the *LeakyReLU* nonlinearity with a negative slope of 0.2. The variable $\alpha_{nk,ml}$ refers to the attention score that is used to quantify the significance of a neighboring node v_{ml} concerning node v_{nk} .

Similarly, the resulting weights which are normalized using the softmax function foredge $e_{nk,ml}$ is expressed as:

$$\begin{aligned} \alpha_{nk,(nk,ml)} &= softmax_{(nk,ml)} (c_{nk,(nk,ml)}) \\ &= \left(\frac{\exp(\sigma(\beta_e^T [W_n \mathbf{n}_{nk} \parallel W_e \mathbf{e}_{nk,ml}]])}{\sum_{(rs,tu) \in \mathcal{E}_i} \exp(\sigma(a_e^T [W_n \mathbf{n}_{nk} \parallel W_e \mathbf{e}_{rs,tu}]])} \right), \end{aligned} \quad (8)$$

where $\beta_e^T \in \mathbb{R}^{d'_V + d'_E}$ denotes the attention vector for edge-based neighbors. The variable $\alpha_{nk,(nk,ml)}$ refers to the attention score that used to quantify the significance of a neighboring edge $e_{nk,ml}$ concerning node v_{nk} .

Hence, the node-based neighbors' embedding of node v_{nk} is computed by aggregating the features of its first-order neighbors and weighted by the attention score:

$$\mathbf{n}_{nk} [\mathcal{N}_{nk}] = \sigma \left(\sum_{ml \in \mathcal{N}_{nk}} \alpha_{nk,ml} W_n \mathbf{n}_{ml} \right), \quad (9)$$

where σ is the activation function, \mathbf{n}_{nk}^{L+1} is the new feature of each vertex v_{nk} aggregated with neighborhood information.

Similarly, the edge-based neighbors' embedding of node v_{nk} is expressed as:

$$\mathbf{n}_{nk} [\mathcal{E}_{nk}] = \sigma \left(\sum_{(nk,ml) \in \mathcal{E}_{nk}} \alpha_{nk,(nk,ml)} W_e \mathbf{e}_{(nk,ml)} \right). \quad (10)$$

To make the learning process of the self-attention mechanism more robust, we use a multi-headed attention mechanism, which can be viewed as multiple single-headed attentions executed independently in parallel and averaged as the output. Then $\mathbf{n}_{nk}^{L+1} [\mathcal{N}_{nk}]$ and $\mathbf{n}_{nk}^{L+1} [\mathcal{E}_{nk}]$ can be calculated as:

$$\mathbf{n}_{nk} [\mathcal{N}_{nk}] = \sigma \left(\frac{1}{Q} \sum_{q=1}^Q \sum_{ml \in \mathcal{N}_{nk}} \alpha_{nk,ml}^q W_n^q \mathbf{n}_{ml} \right), \quad (11)$$

$$\mathbf{n}_{nk} [\mathcal{E}_{nk}] = \sigma \left(\frac{1}{Q} \sum_{q=1}^Q \sum_{(nk,ml) \in \mathcal{E}_{nk}} \alpha_{nk,(nk,ml)}^q W_e^q \mathbf{e}_{(nk,ml)} \right), \quad (12)$$

where the variable Q denotes the number of attention heads, while W^q signifies the weight matrix shared by the q th attention head. The aggregation function

can be classified as either tandem or average. Specifically, when conducting multiple tasks at the final stage, the method of averaging is employed.

At last, by integrating the edge-based neighbors' embedding $n_{nk} [\mathcal{E}_{nk}]$ and node-based neighbors' embedding $n_{nk} [\mathcal{N}_{nk}]$, the embedding of node v_{nk} in the $(L + 1)$ -th layer is expressed as:

$$n_{nk}^{L+1} = \text{concat} \left(n_{nk}^L [\mathcal{N}_{nk}] \parallel n_{nk}^L [\mathcal{E}_{nk}] \right), \quad (13)$$

where *concat* denotes the operation of concatenation.

Upon the integration of the previously discussed components, the resulting node representation becomes accessible, thus facilitating its application in a range of subsequent tasks. HEGAT is trained through a supervised learning methodology that considers task-specific attributes of nodes. The model's weights are effectively refined using back-propagation and gradient descent techniques. The objective of this process is to minimize cross-entropy, ultimately yielding meaningful node embeddings for heterogeneous networks.

4.3. Training Samples Generation. The current research study makes a suggestion for a semi-supervised training strategy that may be used for the HEGAT-based architecture. This method requires a significant quantity of labeled training data. According to a study that compared many stochastic search-based algorithms to discover the estimated optimum power allocation, the Particle Swarm Optimization (PSO) approach outperformed all others in a range of application circumstances. This was determined by comparing the algorithms' performance. A collection of candidate solutions for the optimization issue that is being considered in this work is first generated at random. These candidate solutions are then moved throughout the search space according to rules that have been defined, and the search is guided by optimal positions that are already known to exist. The goal of this process is to identify the best option for allocating resources. When new prospective solutions are found, their locations are mapped out and used to influence the movement of those that are close by. After a number of iterations, the PSO approach produces outcomes that are very close to being optimum. These replies may be used as labels for the expected graph locations, and we record the properties of the sample graph, including information about the graph's structure and channels, at the positions corresponding to those labels.

The graph neural network we use learns resource allocation strategies through semi-supervised learning. We run the simulated environment and record a graph representation of the network realization, including the graph topology and channel states. The graph representation of each time point

is regarded as an independent sample, regardless of the dependence of the user's state on the front and back time, and the users in the network are randomly distributed. Among them, the power allocation and beamforming vector as optimization variables are used as features of each vertex and are also variables predicted by the graph neural network. The loss function L is the negative expectation of utility function over different channel realizations: $\mathcal{L}(\theta) = -E_H [\sum_{i,m} B \log(1 + \gamma_{nk})]$, which updates the model parameters θ of HEGAT by backpropagation of the neural network. This is an optimization process of a static graph. The graph neural network learns the mapping relationship between the topology of the graph and the channel state to the optimal resource allocation strategy. Essentially graph neural networks are data-driven optimization methods, and whether or not the sample contains as comprehensive a network realization as possible determines the upper bound of the model.

5. Illustrative Results

5.1. Simulation Environment Setting. Through the use of numerical simulations, this part evaluates the effectiveness of the proposed GAT framework for solving the challenge of maximizing the total rate. We evaluate the suggested methodology in comparison to a variety of standards derived from past research. The computer that was utilized to do the simulation studies for this research has a Central Processing Unit (CPU) with a speed of 3.19 GHz and 32 Gigabytes of Random Access Memory (RAM). In the recommended method, Python 3.6 is utilized as the platform for the simulation, while Pytorch is the tool of choice for the development of the neural network. Table 1 presents both the cellular network and the neural network's corresponding parameters for your perusal.

Table 1. Simulation parameters

Number of BS	9
Average users per cell	4
The Doppler frequency	10 HZ
Minimum allocated power	5 dBm
Maximum allocated power	38 dBm
Inner space distance	0.01 km
Half cell-to-cell distance	1 km
Noise power spectral density	- 114 dBm/Hz
Learning rate	0.0001
Number of layers	3
Optimizer	ADAM
Batch size	32
Epoch count	300

5.2. Performance Comparison. In order to evaluate the efficacy of the proposed HEGAT, a thorough comparison study is conducted, encompassing many cutting-edge baseline approaches. The present analysis incorporates many strategies, such as network embedding approaches and techniques based on graph neural networks.

- GAT: GAT incorporates an attention mechanism that operates on homogeneous graphs. In this study, we conduct an evaluation of several meta-paths and provide the findings on the optimal performance achieved.

- GCN: The GCN architecture proposed in [11] captures the deep features of topology in the network. The topology and channel information are concatenated as input features, and then the model is trained offline in a semi-supervised manner.

- Multi-Layer Perception (MLP): A fully connected neural network is designed to build a mapping from channel information to power allocation through the data of the Euclidean structure. This approach has been studied in [27].

The performance evaluation of HEGAT is conducted as the network scale expands, in comparison to benchmarks. As illustrated in Figure 4, the average sum rate per UE achieved by HEGAT exhibits notable enhancements of 9.14%, 9.68%, and 10.2% respectively, as opposed to the leading benchmark GAT, with the increase in the number of cell pairs from 4 to 16.




Fig. 4. Average sum rate per UE versus cellular network scale

Notably, HEGAT demonstrates robust generalization capabilities while simultaneously achieving optimal performance. The effectiveness of the proposed edge feature enhanced mechanism can be attributed to its ability to proficiently extract features from the channel state of the edge attributes, resulting in a further augmentation of the effectiveness of the initial node update approach.

The performance of each algorithm for various cellular network densities is shown in Figure 5. The simulation takes into consideration the inherent fluctuations in user density, reflecting the real-world intricacies of time and spatial factors. The user density is subject to variations contingent upon the number of UEs present within a specific cell, and this value ranges from 1 to 6. As the user density escalates, a concomitant decline in the average total rate becomes evident. This consistent trend is observed across all algorithms, implying a shared behavior among them. To assess the performance of the proposed technique in high-density networks, we change the number of UEs in the cell while maintaining the other parameters constant ($N=16$). The average sum rate per UE drops when network density rises as a result of the rise in interference. It is important to note that the GAT algorithm continues to perform better than other algorithms at boosting the overall network rate.

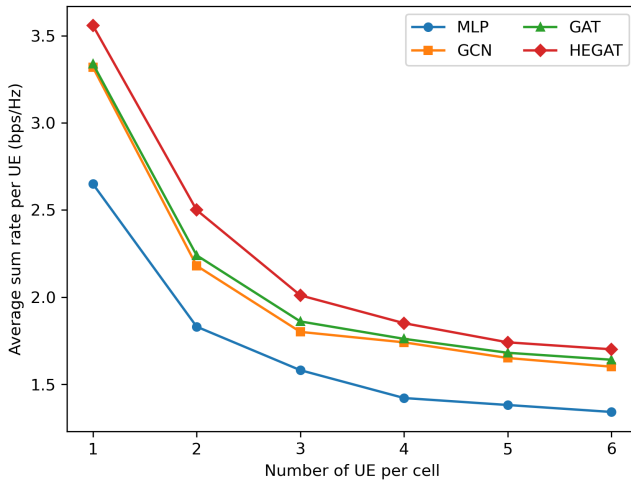


Fig. 5. Average sum rate per UE versus network density

Figure 6 illustrates the performance of the algorithms with respect to different cellular network radii. In this section, we explore the variability of the range between half a BS degree and a full BS degree, which is represented as R_{max} . In general, it is observed that a decrease in cell range has a tendency to amplify both intra-cell and inter-cell interference, resulting in a decrease in the average total rate. The aforementioned tendency is notably apparent in the overall rate performance, as the random and maximal power tactics demonstrate the least effectiveness. The mean rate per UE increases as the radius increases within the range of 0.2 km to 0.4 km for the half-cell length. The mean rate per UE does not significantly increase beyond a distance of 0.4 km, which corresponds to half the length of a cell. The data clearly indicates that the influence of cell radius on the overall rate enhancement has significantly lessened. The performance of the HEGAT algorithm across different network settings illustrates its effectiveness and reliability.

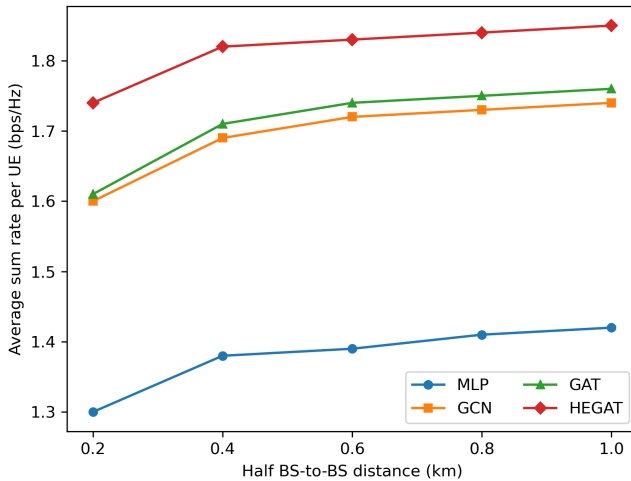


Fig. 6. Average sum rate per UE versus cell length

As shown in Figure 7, the HEGAT demonstrates a runtime that is similar to that of previous benchmark algorithms. The comparable runtime of these approaches may be ascribed to the utilization of the same network architecture and input characteristics. However, the strategy that has been suggested exhibits a higher level of time consumption in comparison to alternative benchmark techniques. The reason for this is the increased amount of time needed to

get and combine the embedding information of both nodes and edges. Every node iteratively enhances its own embedding characteristics together with the embedding features of its neighboring nodes and edges. When the quantity of BS reaches 16, HEGAT exhibits a computational duration of 0.01 seconds, which is notably below the required timeframe for decision-making in wireless systems, namely 0.02 seconds. This solution satisfactorily addresses the need of making real-time judgments. Therefore, the proposed methodology exhibits effectiveness in enabling immediate implementation into wireless networks.




Fig. 7. Computation time comparison

As shown in Figure 8, the doppler frequency, denoted as f_d , is a crucial quantity that is closely associated with the phenomena of small-scale fading. The incorporation of real-time data into our suggested data-driven methodology for instantaneous power distribution may encounter obstacles arising from the swift variations in signal intensity. The observed oscillations have the potential to result in a decrease in overall performance. The Doppler frequency is seen to occur within a frequency range that extends from 4 Hz to 18 Hz. The simulation results presented in Figure 8 reveal a steady decrease in the average sum rate associated with the data-driven algorithm as the values of f_d span throughout this frequency range. This fascinating discovery suggests that the data-driven model has the ability to withstand the changes offered by f_d .




Fig. 8. Average sum rate per UE versus doppler frequency

6. Discussion and Conclusion

6.1. Discussion. From the perspective of the convolution operator, the graph neural network can be divided into two categories, spectral methods and spatial methods.

Spectral methods: e.g., GCN, depend on Laplacian eigenbasis of the graph, which is hard to calculate for a large graph. Its main drawbacks: 1) the edge weights are fixed when fusing, not flexible enough; 2) poor generalizability because it is a full graph convolutional fusion, the whole graph does gradient update, and when the graph is larger, such an approach is too slow and inappropriate.

Spatial methods: e.g., GAT, perform information aggregation only on the local neighborhood, avoiding heavy calculation of Laplacian eigenbasis. The HEGAT algorithm proposed in this paper is based on the attention aggregation mechanism of GAT, and the performance degradation is weaker and more stable than that of the spectral graph-based neural network when the graph structure is changed.

Different graph tasks may have different preferences for node and edge features. There are some graphs where node features have a greater impact on the graph and some graph edges where edge features have a greater impact on the graph. Whereas, in the graph representation of cellular networks, direct

links from BS-to-UE are considered as nodes and channel gain of the desired signal is considered as node features. The interference links between different BS-to-UEs are regarded as edges, and channel gain of interference is regarded as node features. While the latter is computed from the former and the topology of the graph, the edge characteristics are strongly correlated with the node characteristics. So essentially the graph representation in cellular networks is still a node-sensitive task. Edge features are used as a complement to enhance the performance of the graph neural network.

6.2. Conclusion. This study introduces a framework called HEGAT, which has been developed to tackle the issue of power regulation in cellular networks. The cellular network is represented as a heterogeneous directed graph, and the network parameters of HEGAT are trained using a semi-supervised learning technique. The HEGAT framework successfully incorporates node and edge properties, resulting in a notable improvement in node and edge embeddings across various neural network layers. This technique effectively captures the significance of adjacent nodes and edges inside the network. The experimental findings derived from thorough studies conducted on huge datasets of mobile traffic provide evidence of the almost ideal performance of our proposed strategy. Moreover, the system demonstrates robust generalization abilities across many network conditions. In anticipation of future endeavors, our research agenda includes the investigation of complex heterogeneous network settings, enhancement of current approaches, and the incorporation of multi-source datasets to attain higher levels of prediction accuracy. In future work, we will continue research in this area to verify the versatility of HEGAT in different network scenarios.

References

1. Jiang W. Graph-based deep learning for communication networks: A survey. *Computer Communications*. 2022. vol. 185. pp. 40–54.
2. Shi Q., Razaviyayn M., Luo Z.Q., He C. An iteratively weighted MMSE approach to distributed sum-utility maximization for a MIMO interfering broadcast channel. *IEEE Transactions on Signal Processing*. 2011. vol. 59. no. 9. pp. 4331–4340.
3. Shen K., Yu W. Fractional programming for communication systems – Part I: Power control and beamforming. *IEEE Transactions on Signal Processing*. 2018. vol. 66. no. 10. pp. 2616–2630.
4. Feiten A., Mathar R., Reyer M., Rate and power allocation for multiuser OFDM: An effective heuristic verified by branch-and-bound. *IEEE Transactions on Wireless Communications*. 2008. vol. 7. no. 1. pp. 60–64.
5. Sun Q., Wu H., Petrosian O. Optimal Power Allocation Based on Metaheuristic Algorithms in Wireless Network. *Mathematics*. 2022. vol. 10(18). no. 3336.
6. Sun H., Chen X., Shi Q., Hong M., Fu X., Sidiropoulos N.D. Learning to optimize: Training deep neural networks for interference management. *IEEE Transactions on Signal Processing*. 2018. vol. 66. no. 20. pp. 5438–5453.

7. Liang F., Shen C., Yu W. and Wu F. Towards optimal power control via ensembling deep neural networks. *IEEE Transactions on Communications*. 2019. vol. 68. no. 3. pp. 1760–1776.
8. Lee W., Kim M., Cho D.H. Deep learning based transmit power control in underlaid device-to-device communication. *IEEE Systems Journal*. 2018. vol. 13. no. 3. pp. 2551–2554.
9. Liao X., Shi J., Li Z., Zhang L., Xia B. A model-driven deep reinforcement learning heuristic algorithm for resource allocation in ultra-dense cellular networks. *IEEE Transactions on Vehicular Technology*. 2019. vol. 69. no. 1. pp. 983–997.
10. Shen Y., Shi Y., Zhang J., Letaief K.B. A graph neural network approach for scalable wireless power control. *IEEE Globecom Workshops (GC Wkshps)*. 2019. pp. 1–6.
11. Chowdhury A., Verma G., Rao C., Swami A., Segarra S. Unfolding WMMSE using graph neural networks for efficient power allocation. *IEEE Transactions on Wireless Communications*. 2021. vol. 20. no. 9. pp. 6004–6017.
12. Li B., Swami A., Segarra S. Power allocation for wireless federated learning using graph neural networks. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2022. pp. 5243–5247.
13. Wang X., Ji H., Shi C., Wang B., Ye Y., Cui P., Yu P.S. Heterogeneous graph attention network. *The world wide web conference*. 2019. pp. 2022–2032.
14. Busbridge D., Sherburn D., Cavallo P., Hammerla N.Y. Relational graph attention networks. *arXiv preprint*. 2019. arXiv:1904.05811.
15. Gong L., Cheng Q. Exploiting edge features for graph neural networks. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2019. pp. 9211–9219.
16. Jiang X., Ji P., Li S. CensNet: Convolution with Edge-Node Switching in Graph Neural Networks. *IJCAI*. 2019. pp. 2656–2662.
17. Fu X., Zhang J., Meng Z., King I. Magnn: Metapath aggregated graph neural network for heterogeneous graph embedding. *Proceedings of The Web Conference*. 2020. pp. 2331–2341.
18. Zhang X., Zhao H., Xiong J., Liu X., Zhou L., Wei J. Scalable power control/beamforming in heterogeneous wireless networks with graph neural networks. *IEEE Global Communications Conference (GLOBECOM)*. 2021. pp. 01–06.
19. Guo J., Yang C. Learning power allocation for multi-cell-multi-user systems with heterogeneous graph neural networks. *IEEE Transactions on Wireless Communications* 2021. vol. 21. no. 2. pp. 884–897.
20. Khodmi A., Rejeb S.B., Agoulmine N., Choukair Z. A joint power allocation and user association based on non-cooperative game theory in an heterogeneous ultra-dense network. *IEEE Access*. 2019. vol. 7. pp. 111790–111800.
21. Challita U., Saad W., Bettstetter C. Interference management for cellular-connected UAVs: A deep reinforcement learning approach. *IEEE Transactions on Wireless Communications*. 2019. vol. 18. no. 4. pp. 2125–2140.
22. Nguyen L.D., Tuan H.D., Duong T.Q., Poor H.V. Multi-user regularized zero-forcing beamforming. *IEEE Transactions on Signal Processing*. 2019. vol. 67. no. 11. pp. 2839–2853.
23. Li Y., Han S., Yang C. Multicell power control under rate constraints with deep learning. *IEEE Transactions on Wireless Communications*. 2021. vol. 20. no. 12. pp. 7813–7825.
24. Wang X., Ji H., Shi C., Wang B., Ye Y., Cui P., Yu P.S. Heterogeneous graph attention network. *The world wide web conference*. 2019. pp. 2022–2032.
25. Yang Y., Li D. Nenn: Incorporate node and edge features in graph neural networks. *Asian conference on machine learning*. 2020. pp. 593–608.

26. Chen J., Chen H. Edge-featured graph attention network. arXiv preprint. 2021. arXiv:2101.07671.
27. Kim J., Park J., Noh J., Cho S. Autonomous power allocation based on distributed deep learning for device-to-device communication underlying cellular network. IEEE access. 2020. vol. 8. pp. 107853–107864.

Qiushi Sun — Graduate student, Faculty of applied mathematics and control process, St. Petersburg State University. Research interests: mathematical statistics, system control, intelligent manufacturing. The number of publications — 3. st059656@student.spbu.ru; 35, Universitetskiy Av., 198504, St. Petersburg, Peterhof, Russia; office phone: +7(911)740-8019.

Yang He — Graduate student, Faculty of applied mathematics and control process, St. Petersburg State University. Research interests: mathematical statistics, system control, intelligent manufacturing. The number of publications — 1. hy1186867324@outlook.com; 35, Universitetskiy Av., 198504, St. Petersburg, Peterhof, Russia; office phone: +7(812)428-4530.

Petrosian Ovanes — Ph.D., Professor of the department, Department of mathematical modeling of energy systems, St. Petersburg State University. Research interests: machine learning, reinforcement Learning, time series analysis, graph theory, discrete probability models and stochastic processes and game theory, operations research. The number of publications — 81. o.petrosyan@spbu.ru; 35, Universitetskiy Av., 198504, St. Petersburg, Peterhof, Russia; office phone: +7(812)428-4530.

Acknowledgements. This work was supported by St. Petersburg State University (grant 94-06-2114).

С. Цюши, Х. Ян, О.Л. ПЕТРОСЯН

РАСПРЕДЕЛЕНИЕ МОЩНОСТИ В БЕСПРОВОДНОЙ СОТОВОЙ СИСТЕМЕ С ПРИМЕНЕНИЕМ ГРАФОВОЙ СЕТИ ВНИМАНИЯ

Цюши С., Ян Х., Петросян О.Л. Распределение мощности в беспроводной сотовой системе с применением графовой сети внимания.

Аннотация. С быстрым развитием технологии сотовых сетей и распространением мобильных устройств эффективная политика распределения сетевых ресурсов становится все более важной для улучшения пользовательских услуг и производительности сети. Наша цель – максимизировать суммарную мощность всех пользователей сети путем нахождения оптимальной схемы распределения мощности. В последние годы методы глубокого обучения на основе графов продемонстрировали большой потенциал для решения проблемы распределения сетевых ресурсов. Из-за топологической природы мобильных сетей графовые нейронные сети (GNN) могут лучше работать с данными, структурированными в виде графов. Однако большинство из этих методов фокусируются только на узловых функциях в процессе обучения и часто игнорируют или упрощают граничные функции, которые играют не менее важную роль, чем узлы. Чтобы решить эту проблему, мы предлагаем дизайн сети с расширенным графическим вниманием (HEGAT), который напрямую связывает изменяющуюся топологию сети и наилучший способ распределения мощности во время обучения. Обширные результаты моделирования подтверждают превосходную производительность и надежные возможности обобщения, демонстрируемые предлагаемой методологией HEGAT.

Ключевые слова: МИСО, сотовая сеть, пограничная функция, сеть графического внимания, распределение мощности.

Литература

1. Jiang W. Graph-based deep learning for communication networks: A survey. *Computer Communications*. 2022. vol. 185. pp. 40–54.
2. Shi Q., Razaviyayn M., Luo Z.Q., He C. An iteratively weighted MMSE approach to distributed sum-utility maximization for a MIMO interfering broadcast channel. *IEEE Transactions on Signal Processing*. 2011. vol. 59. no. 9. pp. 4331–4340.
3. Shen K., Yu W. Fractional programming for communication systems – Part I: Power control and beamforming. *IEEE Transactions on Signal Processing*. 2018. vol. 66. no. 10. pp. 2616–2630.
4. Feiten A., Mathar R., Reyser M., Rate and power allocation for multiuser OFDM: An effective heuristic verified by branch-and-bound. *IEEE Transactions on Wireless Communications*. 2008. vol. 7. no. 1. pp. 60–64.
5. Sun Q., Wu H., Petrosian O. Optimal Power Allocation Based on Metaheuristic Algorithms in Wireless Network. *Mathematics*. 2022. vol. 10(18). no. 3336.
6. Sun H., Chen X., Shi Q., Hong M., Fu X., Sidiropoulos N.D. Learning to optimize: Training deep neural networks for interference management. *IEEE Transactions on Signal Processing*. 2018. vol. 66. no. 20. pp. 5438–5453.
7. Liang F., Shen C., Yu W. and Wu F. Towards optimal power control via ensembling deep neural networks. *IEEE Transactions on Communications*. 2019. vol. 68. no. 3. pp. 1760–1776.

8. Lee W., Kim M., Cho D.H. Deep learning based transmit power control in underlaid device-to-device communication. *IEEE Systems Journal*. 2018. vol. 13. no. 3. pp. 2551–2554.
9. Liao X., Shi J., Li Z., Zhang L., Xia B. A model-driven deep reinforcement learning heuristic algorithm for resource allocation in ultra-dense cellular networks. *IEEE Transactions on Vehicular Technology*. 2019. vol. 69. no. 1. pp. 983–997.
10. Shen Y., Shi Y., Zhang J., Letaief K.B. A graph neural network approach for scalable wireless power control. *IEEE Globecom Workshops (GC Wkshps)*. 2019. pp. 1–6.
11. Chowdhury A., Verma G., Rao C., Swami A., Segarra S. Unfolding WMMSE using graph neural networks for efficient power allocation. *IEEE Transactions on Wireless Communications*. 2021. vol. 20. no. 9. pp. 6004–6017.
12. Li B., Swami A., Segarra S. Power allocation for wireless federated learning using graph neural networks. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2022. pp. 5243–5247.
13. Wang X., Ji H., Shi C., Wang B., Ye Y., Cui P., Yu P.S. Heterogeneous graph attention network. *The world wide web conference*. 2019. pp. 2022–2032.
14. Busbridge D., Sherburn D., Cavallo P., Hammerla N.Y. Relational graph attention networks. *arXiv preprint*. 2019. arXiv:1904.05811.
15. Gong L., Cheng Q. Exploiting edge features for graph neural networks. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2019. pp. 9211–9219.
16. Jiang X., Ji P., Li S. CensNet: Convolution with Edge-Node Switching in Graph Neural Networks. *IJCAI*. 2019. pp. 2656–2662.
17. Fu X., Zhang J., Meng Z., King I. Magnn: Metapath aggregated graph neural network for heterogeneous graph embedding. *Proceedings of The Web Conference*. 2020. pp. 2331–2341.
18. Zhang X., Zhao H., Xiong J., Liu X., Zhou L., Wei J. Scalable power control/beamforming in heterogeneous wireless networks with graph neural networks. *IEEE Global Communications Conference (GLOBECOM)*. 2021. pp. 01–06.
19. Guo J., Yang C. Learning power allocation for multi-cell-multi-user systems with heterogeneous graph neural networks. *IEEE Transactions on Wireless Communications*. 2021. vol. 21. no. 2. pp. 884–897.
20. Khodmi A., Rejeb S.B., Agoulmine N., Choukair Z. A joint power allocation and user association based on non-cooperative game theory in a heterogeneous ultra-dense network. *IEEE Access*. 2019. vol. 7. pp. 111790–111800.
21. Challita U., Saad W., Bettstetter C. Interference management for cellular-connected UAVs: A deep reinforcement learning approach. *IEEE Transactions on Wireless Communications*. 2019. vol. 18. no. 4. pp. 2125–2140.
22. Nguyen L.D., Tuan H.D., Duong T.Q., Poor H.V. Multi-user regularized zero-forcing beamforming. *IEEE Transactions on Signal Processing*. 2019. vol. 67. no. 11. pp. 2839–2853.
23. Li Y., Han S., Yang C. Multicell power control under rate constraints with deep learning. *IEEE Transactions on Wireless Communications*. 2021. vol. 20. no. 12. pp. 7813–7825.
24. Wang X., Ji H., Shi C., Wang B., Ye Y., Cui P., Yu P.S. Heterogeneous graph attention network. *The world wide web conference*. 2019. pp. 2022–2032.
25. Yang Y., Li D. Nenn: Incorporate node and edge features in graph neural networks. *Asian conference on machine learning*. 2020. pp. 593–608.
26. Chen J., Chen H. Edge-featured graph attention network. *arXiv preprint*. 2021. arXiv:2101.07671.

27. Kim J., Park J., Noh J., Cho S. Autonomous power allocation based on distributed deep learning for device-to-device communication underlying cellular network. IEEE access. 2020. vol. 8. pp. 107853–107864.

Цюши Сунь — аспирант, факультет прикладной математики и процессов управления, Санкт-Петербургский государственный университет. Область научных интересов: математическая статистика, системное управление, интеллектуальное производство. Число научных публикаций — 3. st059656@student.spbu.ru; Университетский проспект, 35, 198504, Санкт-Петербург, Петергоф, Россия; р.т.: +7(911)740-8019.

Ян Хе — аспирант, факультет прикладной математики и процессов управления, Санкт-Петербургский государственный университет. Область научных интересов: математическая статистика, системное управление, интеллектуальное производство. Число научных публикаций — 1. hu1186867324@outlook.com; Университетский проспект, 35, 198504, Санкт-Петербург, Петергоф, Россия; р.т.: +7(812)428-4530.

Петросян Ованес Леонович — канд. техн. наук, профессор кафедры, кафедра математического моделирования энергетических систем, Санкт-Петербургский государственный университет. Область научных интересов: электронное машинное обучение, обучение с подкреплением, анализ временных рядов, теория графов, дискретные вероятностные модели и стохастические процессы, а также теория игр, исследование операций. Число научных публикаций — 81. o.petrosyan@spbu.ru; Университетский проспект, 35, 198504, Санкт-Петербург, Петергоф, Россия; р.т.: +7(812)428-453.

Поддержка исследований. Эта работа была поддержана Санкт-Петербургским государственным университетом (грант 94-06-2114).

B. SWAPNA, V. DIVYA

**LATENCY AWARE INTELLIGENT TASK OFFLOADING
SCHEME FOR EDGE-FOG-CLOUD COMPUTING – A REVIEW***Swapna B., Divya V. Latency Aware Intelligent Task Offloading Scheme for Edge-Fog-Cloud Computing – a Review.*

Abstract. The huge volume of data produced by IoT procedures needs the processing power and space for storage provided by cloud, edge, and fog computing systems. Each of these ways of computing has benefits as well as drawbacks. Cloud computing improves the storage of information and computational capability while increasing connection delay. Edge computing and fog computing offer similar advantages with decreased latency, but they have restricted storage, capacity, and coverage. Initially, optimization has been employed to overcome the issue of traffic dumping. Conversely, conventional optimization cannot keep up with the tight latency requirements of decision-making in complex systems ranging from milliseconds to sub-seconds. As a result, ML algorithms, particularly reinforcement learning, are gaining popularity since they can swiftly handle offloading issues in dynamic situations involving certain unidentified data. We conduct an analysis of the literature to examine the different techniques utilized to tackle this latency-aware intelligent task offloading issue schemes for cloud, edge, and fog computing. The lessons acquired consequently, from these surveys are then presented in this report. Lastly, we identify some additional avenues for study and problems that must be overcome in order to attain the lowest latency in the task offloading system.

Keywords: task offloading, cloud computing, edge computing, fog computing, Internet of things, latency.

1. Introduction. The smart IoT is widely consumed, which allows for the connection of numerous electric sensors and gadgets and produces a higher amount of data flow [1]. IoT products that influence and alter our daily activities consist of smart homes, sickness control and avoidance, and connection [2]. These time-critical applications need a greater amount of power, memory and compute resources. While IoT devices are getting stronger all the time, running big programmes on a single device still puts a strain on the battery, Central Processing Unit (CPU), and memory. One solution to the aforementioned problems is computational offloading, in which the computing tasks are moved to another system for execution [3].

The cloud, on the other hand, is a tried-and-true option with established data center infrastructures that might boost the resource capabilities of end devices. Additionally, the cloud has the requisite automation features and instruments to provide end devices with the transparency they want while concealing the complicated technical and logistical problems of this resource augmentation [4]. As a result, shifting computation-heavy activities of resource-heavy apps to centralised Cloud infrastructure is a well-studied approach [4–6]. Edge computing is a revolutionary computing platform that places edge servers near clients to

perform services including video processing, online gaming, augmented reality (AR), virtual reality (VR), and self-driving automobile applications with recommendation engines. It is required owing to the distance between the final devices and cloud infrastructure, the transport network's reliability, the expense of traveling via the backhaul network, and the wider security surface [7]. Because wireless networks have varied performance, task offloading increases the quantity of data that devices broadcast, implying a longer transmission length and higher transmission energy [8, 9], that results in a shorter device battery life and worse application performance. Edge computing [10] may assist with the previous problem by bringing computing resources (i.e., edge/fog servers) closer to consumer devices, hence reducing communication distances and, as a result, latency. Edge servers, on the other hand, are significantly fewer than cloud servers, as just a few servers may fit in an edge computing center owing to space constraints and restricted cooling capacity [11]. As an outcome, edge computing will probably provide inadequate processing resources for consumers to finish all activities.

Edge-cloud computing, which mixes the profits of cloud and edge computing, provides one of the approaches that is closest to addressing all of the problems mentioned earlier in order to improve user device battery life and application performance. Because each operation is executed on the consumer device, an edge, or a cloud, edge-cloud computing [12] could offer better computation and transmission performance than edge computing or cloud computing collectively. While task offloading is one of the greatest difficult challenges to solve, it is essential to increase resource utilization efficiency in edge clouds. In an edge-cloud system, task offloading comprises selecting which activities are relocated from customer devices, which edge or cloud the work is allocated to, as well as the server that every offloaded function executes on and in what order. The best offloading solutions must take into account a variety of resources, user requirements, complex networks, user mobility, job dependencies, and other considerations, making these decisions difficult. Compared to fog computing, which occurs within the device's local network, edge computing occurs within the device itself. Since there is no round-trip time to the cloud when using fog nodes, they are especially useful for applications that require low latency. The cloud can be used to run programs that can take a long time to execute as well as to regularly save highlights and information from various fog nodes. Because there are still difficulties for further investigations, we evaluate newly released studies on latency-aware task offloading in cooperative edge, fog, and cloud computing in this work. We begin with a complete description of latency-aware intelligent task offloading in edge-cloud situations, followed by a detailed examination of associated studies efforts based on latency.

Following that, we examine unresolved concerns and propose some exciting areas for further study. We hope that our research on service delivery in edge-cloud computing will be useful to both academics and industry.

The rest of the work is structured as below. The second section offers and thoroughly examines the detailed latency of job offloading in edge-cloud computing. Section 4 compiles the challenges and opportunities for additional research. Lastly, Section 5 brings the paper to a close.

2. Task Offloading. Task offloading is a technique of having user equipment operate some computationally expensive programs while wirelessly transmitting the data processed by these applications to an edge server on the condition of weighing continuous or other indicators. As portrayed in Figure 1, the following instances represent possible assessments that could be made while calculating the offload [13].

Local Execution: This means that every phase of the calculation is carried out locally. In general, tasks requiring less computational power are the primary goal of this circumstance.

Full Offloading: The base station wirelessly connects, offloads, and sends the entire computation to the edge server to be processed. This procedure is sometimes referred to as the binary unicast problem and the entire unicast difficulty. This problem shows that the edge service application is not isolated it can execute local computations or outsource them to the edge server.

Partial offloading: If a portion of the calculation may be done locally, the balance is directed to the edge server for execution.




Fig. 1. The architecture of computation offloading 5G networks in edge computing

In Figure 2, a few requirements/important justifications for offloading the tasks are shown. Despite these requirements, the offloading process is also caused by several additional reasons, including energy restrictions, bandwidth restrictions, a lack of server computing power, a lack of available storage, and task size [14].

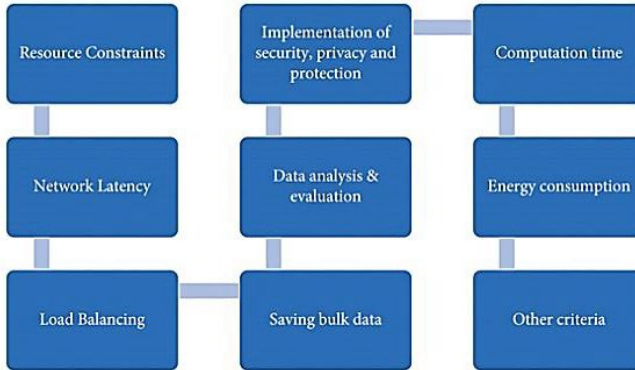


Fig. 2. Task offloading constraints

Some activities have delayed responses, and there is a chance that subsequent jobs might not get resources at all; therefore, latency exists. Therefore, the task offloading (delay) difficulty in cloud-edge-fog computing is explored in their study, while they present advice on how to handle it.

3. Literature Survey. The existing research conducted a review on offloading strategy either cloud or edge or fog. This research examined the major and essential difficulty of latency in the task offloading approach used in cloud, edge, fog, edge-cloud, and fog-cloud computing.

Latency offloading strategy in cloud computing. Cloud service latency is the amount of duration required for a provider of cloud services to reply to a client request. Latency has a substantial influence on device usage and enjoyment. These concerns might be exacerbated for cloud service communications, which could be especially vulnerable to delay due to several factors.

In [15] the authors provided multilevel full and partial offloading solutions using cloudlet, private, and public cloud servers. According to the simulation findings, the suggested multilayer total and partial offloading systems lower power utilization by roughly 8-9% and 20%, respectively. Here, instead of retrieving the data for processing, the authors were transmitting a brief piece of code. However, the suggested system requires more bandwidth and time-consuming for transferring the little objects. Study [16] provides a

simple distributed architecture focused on the alternate direction process of the multipliers procedure to decrease processing latency for all operations. In comparison to current methodologies, the suggested user-assisted computation offloading strategy may minimize calculation latency while retaining high convergence speed. Simulations confirmed the benefits of the suggested user-assisted multi-task offloading approach in terms of minimizing computation latency under diverse conditions. Nonetheless, allocating computing resources will significantly raise the complexity of this challenge.

To improve decision reaction time, in paper [17] the authors proposed a pipelining task offloading method and modeled it as a delay-aware Markov Decision Process (MDP). The researchers then developed a delay-aware MADRL method to lessen the weighted total of job execution latency and power usage. First, the Markov property is rebuilt by enhancing the state space with the most recent state and historical activities. Second, Gate Transformer – extra-long (XL) is introduced to retain the constant input dimension dynamically altered by random transmission delays and to capture the significance of previous events. Third, a sampling approach with a novel loss function with the variations between current with objective state values, as well as the variance between actual state-action value and improved state-action value, are developed to generate state transition trajectories that closely match genuine ones. However, the reaction time difference between the two job-offloading approaches grows as the latency between state collection and action transmission grows.

As a result, in order to meet the aim of minimising average task computation delay while maintaining transmission dependability, a framework for distributed multi-hop computing task offloading depends on an enhanced evolutionary process is suggested by the authors in [18], in which workloads can be recursively distributed among Network Control Protocol (NCPs). The approach optimizes population setup, employs the crossover operator to accelerate convergence, and minimizes the possibility of resource excessive usage resulting from circular schedules by establishing filter chains to filter schedulable nodes before the initialization step. However, finding the best option is tough. In paper [19] the authors introduced a Deep Reinforcement Learning (DRL) depending cooperative task offloading (DCTO) strategy for movement, contact, and load awareness to optimize that. DCTO supports both binary and partial offloading methods, as well as cellular and mm Wave radio access technologies (RATs). DCTO tries to decrease latency by opportunistically switching RATs and offloading mechanisms. When compared to the other evaluated plans, the DRL-based cooperative task offloading proximal policy optimization (DCTO_PPO) method exhibited notable outcomes in terms of reward and TFPS ratio. Consider Table 1.

Table 1. Review on latency offloading strategy in cloud computing

Ref no.	Algorithm	Performance metric	Simulation tool	Offloading type	Objective	Demerits
[15]	Multilevel full offloading strategy	Power and delay	MATLAB 2015	Partial and fully offloading	On cloudlet, private, then public cloud servers, multilevel full also partial offloading algorithms are used	Time-consuming process
[16]	ADMM algorithm	Latency and improved performance efficiently	MATLAB	Partial offloading	To minimise calculation delay while ensuring user energy availability	The allocation of computing resources will significantly raise the difficulty of this task
[17]	Multi-Agent Deep Reinforcement Learning (MADRL)	Decision reaction time and latency	PyTorch 1.10.0 and Python 3.7.11, and the hardware GPU environment is NVIDIA A100-40 GB	Partial offloading	Reduce the total task execution delay and power usage	The time to react variance among the two job offloading strategies grows as the latency between state collection and action transmission grows. This is because the agent of the delay-aware MADRL process doesn't have to wait for the current strategy's response
[18]	Improved genetic algorithm	Latency	Python	Partial offloading	To meet the aim of minimising average task computation latency while keeping transmission dependability in mind	The search solution space grows in proportion to the quantity of the task data. Finding the best option is tricky
[19]	Deep reinforcement learning (DRL)	Latency	Python 3.7 using PyTorch STable (1.13.1)	Fully and partially offloading	Delay reduction by opportunistic switching of RATs and offloading methods	When the amount of activities is significant the system will not operate well

Latency offloading strategy in edge computing. The authors in [20] suggested a latency-aware computation offloading technique for 5G networks. First, some latency and power usage frameworks for 5G edge computing offloading are described. Then, fine-grained computation offloading is used to lessen total task completion time. The method is lengthy to address the problem of multiuser computation offloading. Extensive simulation tests are carried out in order to validate the efficacy of the suggested tactic. The findings indicate that the suggested offloading approach might efficiently minimise task execution latency. Although restricted resources result in a high rate of resource contention, certain irrational judgments happen owing to a shortage of total network knowledge.

Furthermore, in study [21] the authors offered Nimbus, a task placement and offloading solution for a multi-tier edge-cloud design wherein DL responsibilities for Augmented Reality (AR) applications removed from the pipeline and offloaded to adjacent Graphics Processing Unit (GPU)-powered edge devices. To validate Nimbus' efficiency, the researchers employed trace-driven simulations. The authors demonstrated the potential of Nimbus in enhancing the effectiveness of augmented reality services when offloaded from mobile devices to an edge-cloud structure using a large amount of actual data and experiments. According to the stringent latency limits imposed by immersive applications including AR/VR, the deployment of edge servers in the network is required. As a result, study [22] proposed an innovative design whereby task queue lengths are subject to probabilistic and statistical constraints that are calculated via extreme value theory in order to reduce consumers' electrical usage while trading off the allocated resources for local computation and task offloading. To achieve this purpose, the resources given for local computing and task offloading must be balanced with the energy utilization of the consumers. In this context, a user-server association technique is developed that takes channel quality into consideration as well as server workloads and computing capabilities. By combining matching theory with Lyapunov optimization tools, a two-timescale technique is given in which the long timeframe is utilized to address a user-server association issue, and the short timescale is employed to execute a dynamic job offloading and resource allocation strategy. Currently, ML strategies to reduce latency and dependability are needed.

As a result, study [23] suggested a deep deterministic policy gradient (DDPG) technique for determining offloading strategy. The Deep Deterministic Policy Gradient-based technique, allowing task offloading in

multi-server multi-smart mobile devices (SMD) and multi-task mobile edge computing (MEC) with ultra-low latency and expands long-term performance by at least 19%, is detailed. During the resolution process, the dynamic communication environment and the fluctuating server status information across continuous time intervals are taken into account. The researchers can get the offloading object and offloading sections of jobs in every tiny region using the offloading technique. Even so, Offload-MBS and Offload-Local strategies cannot provide a satisfactory user experience in a multi-SMD scenario. In paper [24] the authors presented a two-stage joint optimum offloading approach, optimizing computation along with resource allocation under restricted energy and sensitive latency, to investigate the trade-off between latency and power utilization in low-cost large-scale marine communication. Considering their needs and circumstances, the marine users decide in the first stage whether to offload a computation. In the next phase, the offloading strategy was optimized, taking into consideration the dynamic trade-off between latencies and power consumption, and coordinated with the center cloud servers. Although as the amount of tasks accessed grows, these solutions become increasingly susceptible to delay.

To shorten the overall completion time study [25] demonstrated a simple yet effective offloading strategy for multiuser Edge networks that offloads many important IoT tasks/subtasks to edge servers to minimize anticipated execution time. This is accomplished by explicitly taking into account 1) IoT job topology/schedules; 2) heterogeneous resources on edge servers; and 3) wireless interference in multi-access edge networks. Nonetheless, to increase the offloading efficiency, there is a need to develop a novel optimization algorithm. As a result, study [26] introduced an offloading approach for the joint optimization of telecommunication then processing resources while accounting for the blue trade-off amongst latency and energy utilization. The approach is offered as a tactic for an optimization issue in which the overall power usage is minimized while the execution latency restriction (or deadline) is satisfied. The ideal gearbox power, rate, and proportion of the task to be offloaded are computed analytically and utilized in a solution to satisfy the optimization purpose. Although partial offloading is an extremely complicated procedure that is influenced by a variety of circumstances.

To circumvent the aforementioned constraint, in this study [27] the authors proposed a flexible MEC-based requirement-adaptive partial offloading system to cater to every consumer's unique demands in terms of delay and then consumed energy. The writers gave two normalized

variables to account for the dimensional disparities between time and energy and then calculated the computational price of processing operations. To reduce compute overheads while maintaining acceptable delay, task workload, and power restrictions, this paper takes into account realistic fluctuations in user request patterns. However, it increases time complexity. In study [28] the authors concentrated on subtask offloading with logical dependence for IoT applications to reduce weighted task completion latency and power consumption. To investigate subtask dependencies and consider scheduling priorities, subtask-dependent graphs are used specifically. Furthermore, a task offloading technique with dependency assurances for all IoT jobs in multi-server edge networks is provided in order to improve task latency and device power usage.

To minimize total delay, study [29] investigate particularly efficient dynamic spectrum allocation-aided multiuser computation offloading in MEC. To be more exact, the researchers initially concentrated on a static multiuser compute offloading situation before jointly optimizing users' offloading preferences, transmission periods, and resource allocations on Edge Servers (ESs). The authors take into account a dynamic workload and channel offloading scenario for multiuser computation. To efficiently determine the close-to-ideal transmission length in this dynamic context, the researchers offer an online deep reinforcement learning-based technique. However, moving workloads from wireless devices to cloud servers takes time. In paper [30] the authors looked into delay sensitivity-aware computation offloading to maximize task performance benefits by considering into account the state of the network under computation and communication constraints, in addition to the client's tolerance for task delay. The researchers highlight the latency sensitivity of task offloading especially, through an investigation of delay distribution across job groups utilizing a multi-user and multi-server MEC network. The researchers then created a sensitivity-dependent rating system to measure the value of the task's completion and built the Centralised Iterative Redirection Offloading (CIRO) technique to gather all data in the MEC network. By beginning with an early offloading scheme, the CIRO technique allows IoT gadgets to interact along with iteratively redirecting task offloading decisions to boost the offloading scheme until it converges. The summary is presented in Table 2.

Table 2. Review on latency offloading strategy in edge computing

Ref no.	Algorithm	Performance metric	Simulation tool	System	Offloading type	Objective	Demerits
[20]	Delay-aware optimization algorithm	Latency and energy consumption	-	Multi-user	Fully offloading	Decomposing a computer task into numerous subtasks can decrease task delay & total completion time	Although restricted resources result in an elevated amount of resource contention, certain irrational judgments happen owing to a shortage of general network knowledge
[21]	Nimbus task offloading approach	Network latency, inference, and queuing time	NVIDIA Triton	Multi-user	Fully offloading	End-user delay & energy expenses on portable devices should be kept to a minimum	According to the stringent latency limits imposed by immersive systems including AR/VR, the installation of edge servers in the network is required
[22]	Ultra reliable and low latency communication (URLLC)	Task computation and delay performance	-	Multi-user	Partially offloading and fully offloading	To reduce users' energy usage while allocating resources for local computing & task offloading	The researchers will look at distributed ML approaches to minimize latency as well as dependability even more
[23]	Deep deterministic policy gradient approach	latency, effective server utilization, and frequent mobility	The authors consider a scenario that, a network topology of 10 km × 10 km consists of one Macro Base Station (MBS), 100 Small Base stations (SBSs), and trajectories of SMDs. SBSs are uniformly deployed in the MBS signal coverage area located at the center of the MEC network	Multi-user	Parallel offloading	To consume the Markov decision strategy to reduce the time required to complete all tasks & turn this issue into a deep reinforcement learning-based offloading strategy	In a multi-SMD scenario, the Offload-MBS and Offload-Local strategies are unable to offer a satisfactory user interface
[24]	Joint Optimal Offloading Algorithm for Ship Users in Mobile Edge Computing (JOOA)	Resource limitation and latency	The channel bandwidth is 4MHZ, there are 10 channels, and the bandwidth of each channel is nel is -60dBm	Multi-user	-	The goal of this study is to look at the trade-off between delay and power usage in cheap-cost large-scale marine communication	Although as the amount of jobs accessed grows, these solutions become increasingly vulnerable to low latency

Continuation of Table 2

Ref no.	Algorithm	Performance metric	Simulation tool	System	Offloading type	Objective	Demerits
[25]	EFO (earliest finish-time offloading) Algorithm	Overall completion time and delay	UDN network	Multi-user	Binary offloading	To reduce the overall completion time	To optimize the offloading efficiency machine-learning-based approaches need to develop
[26]	Joint optimization of the communication and computational resources	latency constraint, task complexity	Mobile edge computing	Multi-user	Full and partial offloading	Joint optimization for transmission and computational resources by taking the blue trade-off between usage of energy and delay into account	Although partial offloading is an extremely complicated procedure that is influenced by a variety of circumstances
[27]	Delay-Energy Balanced Partial Offloading (DEB-PO) scheme	Energy consumption and delay	MATLAB using CVX on a desktop computer with an Intel Core i7-4790 3.60GHz CPU and 16GB RAM	Multi-user	Partial offloading	To reduce computing overheads by optimizing offloading workloads with power together over tolerable latency restrictions	It increases time complexity
[28]	SDG-task offloading algorithm	latency and energy consumption	Multi-server edge networks	Multi-user	Partial offloading	To reduce the number of weighted task execution delays & power usage	SDG tasks have less parallelism than parallel structure tasks. In contrast, because of logical interdependence among tasks, subtasks run on various servers must communicate data, increasing communication costs
[29]	Deep reinforcement learning-based online algorithm	Latency	MATLAB R2018a with Intel Core i5 2.4 GHz CPU and 8G RAM	Multi-user	Partial and fully offloading	In MEC, optimum dynamic spectrum allocation-assisted multiuser offloading of computation is used to reduce total latency	Workload migration from wireless devices to cloud servers takes time
[30]	Centralized Iterative Redirection Offloading (CIRO) algorithm	Task execution delay	Python	Multi-user and multi-server	Partial offloading	To optimize the computation offloading strategy to maximize the task execution utility	Complexity is increased

The aforementioned studies have contributed major improvements to computation offloading in MEC. Based on the preceding study, we explore the partial offloading mode and resource allocation in a system with several users in the present study. Although balancing edge servers for efficient server utilization hasn't been fully researched in either binary or partial offloading modes, the frequent mobility of several clients in a multi-user MEC system must be considered.

Latency offloading strategy in edge-cloud computing. Cloud computing is considered as a realistic and desirable technique to assist this development due to its ability to provide on-demand access to a massive pool of computational power for service operations and data analytics [31, 32].

To state the limitations of cloud computing, the edge computing concept has emerged, resulting in the creation of a pool of virtually operated storage and processing assets at the network's edge that are within a variety of IoT devices and therefore minimize latency gaps [33, 34]. In addition, the edge computing design prohibits outsourcing task pre-processing and minimizes massive data uploading and downloading, both of these reduce overall service time [35, 36].

However, the effective administration of edge-cloud computing capabilities along with the managing of computational tasks for applications that are latency-sensitive is an essential problem [37], which could require the proposal of a successful task scheduling approach to enhance total service performance while decreasing offloaded task delay.

In relation to the preceding justification, it ought to be observed that the feasible approach to scheduling tasks that are offloaded on the edge-cloud framework requires into account different application features (computational, communications, and latency), resource heterogeneity, and resource utilization, that could be shown as a dynamic multi-objective optimization issue that changes as time goes on [38].

Study [39] suggested a unique methodology for offloading duties in an edge-cloud network to reduce total service time for latency-sensitive applications. This technique employs fuzzy logic techniques and considers resource utilization along with heterogeneity, in addition to application features (including CPU demand, network demand, and delay sensitivity). Additionally, other factors like network congestion have an impact on the network time of transmitted data. As an outcome, approaches like reinforcement learning may prove useful for teaching the framework to make correct judgments but also for monitoring the effectiveness of offloading decisions by observing every action. Furthermore, because this operation trades utilization for a shorter total service duration, it may squander resources at the edge, particularly processing power. More energy-

efficiency solutions (including Virtual Machine migration and auto-scaling horizontal/vertical) need to be added in the forthcoming to address this problem and strike stability amid serving the demands of applications and then effectively applying the Edge/Cloud computing resources (Figure 3).




Fig. 3. An overview of the Edge-Cloud system

In a multi-user situation, in paper [40] the authors suggested a multi-tier edge-cloud computing method for work offloading that is delay-optimal. The difficulty is given as an optimization framework consuming Integer Linear Programming (ILP) approaches to decrease the entire service time of Unmanned Aerial Vehicles. Furthermore, the researchers organized the task offloading challenge as an Integer Linear Programming (ILP) model in order to shorten the overall service time of UAVs. A task offloading algorithm that is more effective was also created using the ILP model's insights. Long latency is, nevertheless, essential for cloud computation. As a result, study [41] proposed a back-pressure algorithm (BMDCO) that created a computational offloading technique for reducing latency to acquire the offloading choice and the number of jobs that may be

offloaded in order to minimize computational delay while improving reaction rate. The researchers then designed an offloading approach to lower the queue length of jobs in every time slot by decreasing the Lyapunov drift optimization issue in order to achieve queue stability while enhancing offloading performance. In study [41] the authors do not include consuming power as one of the tasks in an edge-cloud system (Table 3).

Table 3. Review on latency offloading strategy in edge-cloud computing

Ref no.	Algorithm	Performance metric	Simulation tool	System	Offloading type	Objective	Demerits
[39]	Fuzzy logic algorithm	Delay, time, and resource utilization	Edge-Cloud environment	Multi-user	Partial offloading	To meet the needs of latency-sensitive IoT programs while effectively utilizing resources in Edge-Cloud scenarios	Job duration, the quantity of transmitted data for uploading and downloading data, that may not always be precise owing to the influence of another element
[40]	Delay-optimal task offloading algorithm	Latency and safety concerns are taken into account	MATLAB	Multi-user	Partial offloading	UAVs' entire service duration should be kept as short as possible	Cloud execution necessitates a high level of delay
[41]	BMDCO algorithm	Delay and Response rate	MATLAB R2016b, 8 GB RAM, Intel i5 3.20 GHz CPU, and Windows 10	-	-	To shorten the calculation time and increase the response rate	The energy consumption of the task is considered
[42]	Resource scheduling policy and routing algorithm	Latency and better energy efficiency	Edge-Cloud environment	Multi-user	Partial offloading	To decrease the general system latency of all mobile phones	In our computation model, computing at local devices is not considered
[43]	A joint task offloading and scheduling (JTOS) framework	Delay and energy	SDN Fog Cloud Simulation Tool	Multi-user	Full offloading	To minimize the hybrid delay of all applications	For IoT services, the JTOS fails to offer mobility-aware or location-aware services. This effort is still hampered by safety holes in the fog cloud network

To reduce energy with latency, paper [42] examined the interface of cloud and edge computing, wherein mobile device operations might be

performed a portion at the edge node with the cloud server. To begin, the weighted-sum latency of all mobile gadgets is decreased by developing a combined interaction and compute resource allocation issue. The closed-form optimum task-splitting approach is then resultant using the normalized backhaul connection capacity and the normalized cloud compute capacity. Although the computational paradigm, computing at local devices, is not taken into account, necessitating the use of linear programming to distribute task offloading and scheduling. Then, the authors [43] employ combinatorial integer linear programming (CILP) to solve joint scheduling and management issues. The researchers suggested a joint task offloading and scheduling (JTOS) structure in response to the problem. JTOS has task offloading, sequencing, scheduling, searching, and breakdown parts. Hence, Figure 3 shows the overview of the Edge-Cloud system.

Edge clouds will help meet the strict latency demands of the future types of applications that run in real-time including AR and VR by moving computing, memory, and networking resources nearer to consumer devices.

Latency offloading strategy in fog computing. Fog computing is a distributed computing methodology that is quickly gaining traction because it delivers cloud-like services near to end devices. It improves the computational abilities of mobile nodes and IoT devices by offering cloud-like computing and storage functionalities with lower latency and lower bandwidth usage.

The issue of offloading for latency-sensitive applications may have a solution due to fog computing. Fog devices will significantly minimize processing latency if they are used to process the tasks. This also helps to reduce network congestion that can occur when multiple IoT devices submit information and activities to cloud servers at the same time.

In study [44] the authors developed a dynamic service that chooses jobs that can sustain another offloading. The offloading destination node is selected depending on job type, latency constraints, and quantity of resources required. Three heuristic offloading approaches are proposed in this paper. Every method focuses on a specific job type. An overloaded fog node is allowed to send out one offloading request to implement any of these techniques based on the task offloading priority. Requests for offloading are made to a Software Defined Networking (SDN) controller. The fog node and controller decide the amount of jobs that are offloaded. Although the impact of movement on the intended service wasn't taken into account. To minimize the execution cost of a task burden offloaded to fog devices, study [45] proposed a Quality of Service (QoS)-aware task offloading solution using a brand-new, nature-inspired optimization technique termed the Smart Flower Optimization algorithm (SFOA). When choosing the best fog nodes to offload

computing work to, the suggested technique takes into account QoS characteristics including task deadlines and financial limitations.

Study [46] offered a cost-cutting offloading approach in fog computing, which is a weighted average of energy use and general processing delay for every end-user operation. The researchers leveraged the heterogeneous nature of fog computing nodes with variable CPU frequencies to handle jobs. The individual computational capacity of the fog node was found to be a significant factor in the local task processing time, which in turn affected the overall task processing cost. The authors used semidefinite relaxation (SDR) to an optimization problem to resolve the non-convex optimization problem. The offloading profile of the fog node, in particular, gives insight into work offloading for every fog node with regard to energy and processing time.

The dynamic collaborative task offloading (DCTO) technique, introduced by the authors in [47], depends on the resource circumstances of fog devices. To minimize task execution latency, a job might be performed by a single fog device or by numerous fog devices via parallel processing of subtasks. By comparing the suggested offloading approach to the current methods, rough simulation outcomes indicated significant benefits in drastically decreasing the average latency in networks with an extensive amount of service requests and a diversified fog climate. Certain fogs that have restricted resources are incapable of handling all of the data from a single task. As a result, in paper [48] the authors developed Fog Resource aware Adaptive Task Offloading (FRATO), an architecture for IoT-cloud systems that employs an adaptive task offloading strategy to enable the fastest service providing feasible. FRATO focuses primarily on the usage of the fog resource to establish an optimum offloading technique, involving a collaborative task offloading technique that utilizes the notion of data fragments. To efficiently deploy optimized offloading technologies in resource-constrained environments, two distributed fog resource allocation techniques, task priority-based resource allocation (TPRA) and maximum resource utilization-based allocation (MaxRU), are developed. However, in the iterative procedure, it has a poor convergence rate.

Paper [49] presented the meta-heuristic scheduler Smart Ant Colony Optimisation (SACO) task offloading approach to offload jobs for IoT-sensor applications in a fog environment in order to minimize compute and transmission delay. The numerical results of the proposed Smart Ant Colony Optimization (SACO) method indicate the task offloading algorithm's considerable decrease in latency. In comparison to the Round Robin (RR), throttled procedure, and two bio-inspired methods modified PSO and Bee life algorithm (MPSO and BLA), computational findings show that the suggested

SACO technique has significantly lower latency in task offloading for IoT-sensor functions. Study [50] suggested a Globally Optimal Multi-objective Optimisation method for Task Offloading (GOMOTO) that utilized the performance model to successfully and swiftly realize task offloading. The performance framework for task offloading in a fog computing situation is built utilising network calculus theory. The outcomes display that their suggested approach and technique may successfully reduce the system's total latency and power usage while improving network Quality of Service (QoS). As a result, achieving prompt and dependable job offloading in the fog layer is a significant problem for fog computing technology.

In [51] the authors proposed the distributed computation offloading architecture (DISCO) for offloading splittable workloads in order to obtain a decreased execution period for the fog computing scenario. Through an extensive simulation study, the presented approaches reveal possible benefits in decreasing average latency. The model given in this work can suggest some directions for further research. First, a Helper Node (HN) that can process several tasks or subtasks can be employed with a many-to-many matching model. Several HN users can work together to manage a group of jobs or subtasks with the aim of optimizing the method's latency performance. Although the scheduling of tasks or subtasks for every HN is considered in this circumstance, the externality is also considered (Table 4).

Table 4. Review on latency offloading strategy in fog computing

Ref no.	Algorithm	Performance metric	Simulation tool	System	Offloading type	Objective	Demerits
[44]	Latency-based Fog-to-Fog Offloading LFFO algorithm	Latency	Apache NetBeans. Algorithms were written in Java. 16 GB of RAM	Multi-user	Fully offloading	To shorten the calculation time as well as increase the response rate	The effect of mobility on the proposed service was not considered
[45]	Smart Flower Optimization Algorithm (SFOA)	Delay	Workload-Fog scenarios	Multi-user	-	The subject under consideration is given as the problem of minimizing the cost of implementation of a work burden offloaded to fog devices	Time-consuming process
[46]	Proposed Offloading Strategy	Minimization of the total system cost and task processing delay	MATLAB	Multi-user	Fully offloading	Under energy along with latency limitations, determine the appropriate quantity of task data to be handled locally or offloaded to the preferred fog node and remote cloud	If the primary fog node's computational resource is insufficient, the primary fog node chooses to offload the work to a neighbouring fog node and cloud

Continuation of Table 4

Ref no.	Algorithm	Performance metric	Simulation tool	System	Offloading type	Objective	Demerits
[47]	A dynamic collaborative task offloading (DCTO) approach	Reduce the task execution delay	Python	Multi-user	Full and partial offloading	To meet the delay reduction goal	Heavy workloads (i.e., a = 10 MB) have considerable effects on the fog computing environment because certain fogs with few resources aren't able to handle the entire data of just one task
[48]	FRATO (Fog Resource aware Adaptive Task Offloading) – a framework	Delay	Powerful fogs have 1 GB of RAM and 6 GB of storage	Multi-user	Full task offloading	To deliver context-aware IoT computing capabilities with minimal latency	The PSO approach has the disadvantage of being easier to slide into a local optimum in high-dimensional space while maintaining a low rate of convergence in the repeating phase
[49]	Smart Ant Colony Optimization (SACO)	Latency and processing time	2018b MATLAB. It was run on a PC with a 2,80 GHz Intel(R) Core(TM) i7 CPU M640@2.80 GHz and 8 GB RAM	-	-	Minimizing task offloading time in IoT-Fog environment by considering computation and communication latency	Power consumption is not considered
[50]	Globally Optimal Multi-objective Optimization algorithm for Task Offloading (GOMOTO)	Latency and Energy consumption	JDK 12	Multi-user	-	The complete FN performance concept is defined as the linear weighted total of equivalent delay, power usage, and storage space	As a result, providing consistent and reliable work offloading in the fog layer is a big challenge for fog computing design
[51]	Distributed computation offloading framework (DISCO)	To reduce the average delay	SimPy library in Python	-	Partial offloading	To decrease the processing time in the fog computing atmosphere	Computational complexity

Despite technical breakthroughs, IoT and smartphones remain resource-restricted. Because of their restricted memory, processing, and networking abilities, these gadgets might be unable to independently analyze massive quantities of information or perform compute-intensive processes over an assured time period. If the bulk of data or the complexity of apps grows, these electronics will be impossible to run them for a reasonable length of period.

Latency offloading strategy in cloud-fog computing. The IoT layer (Tier 1), Fog layer (Tier 2), and Cloud layer (Tier 3) are three tiers of a three-layered hierarchical structure Figure 4 that are taken into consideration.

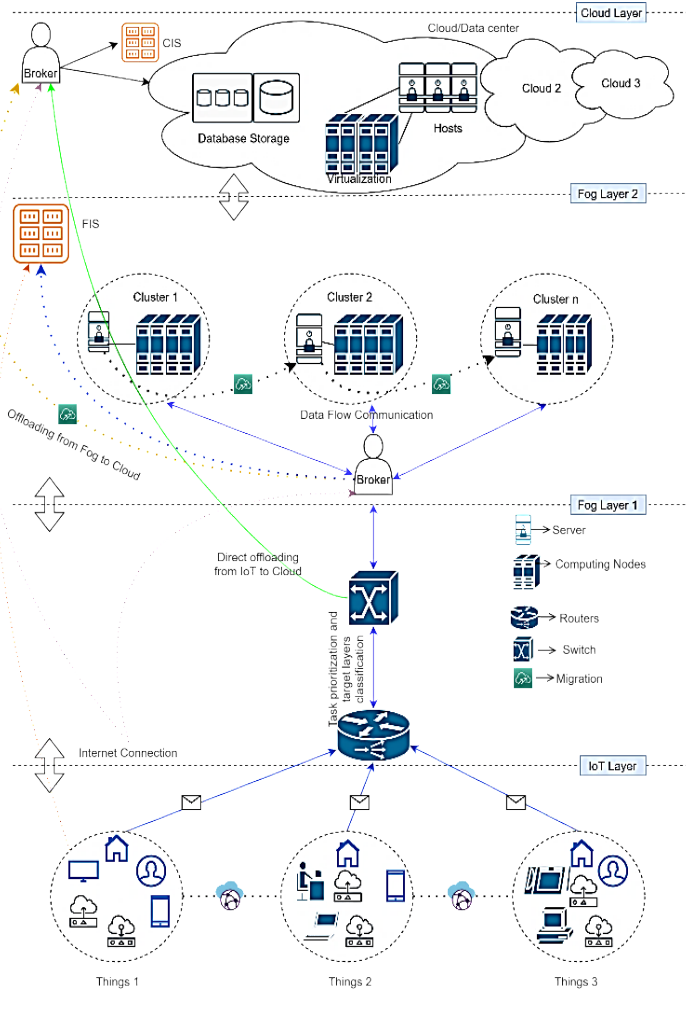


Fig. 4. A three-layered Framework for IoT-Fog-Cloud [52]

In paper [52] the authors suggested a fuzzy logic approach for task prioritization that uses resource needs and deadlines in order to benefit from

the effectiveness of the underlying computing nodes for jobs' heterogeneity and computational requirements with deadline constraints. For effective planning, an elitism-based multi-population Jaya is suggested to map these distinct groupings of activities to a cluster aggregation of computationally capable heterogeneous computing nodes.

A compatibility-based heuristic offloading approach is created as well to locate compatible computing nodes to offload computations while considering the availability of resources and delay in communication from relevant IoT gadgets into account. These activities necessitate the use of increasing resource – and memory-intensive computer nodes for execution. In study [53] the authors suggested a multi-armed bandit (MAB) theory-based optimized offloading system to reduce mean computing task offloading latency. USV cluster nodes may employ this strategy to minimize the average computation task offloading latency by recognizing the potential computing capabilities of their neighboring team nodes. The Adaptive Upper Confidence Boundary (AUCB) method is an optimized technique with related simulations to evaluate performance. Further complicated tasks were not met by this technique.

Less bandwidth equals less delay, which enhances reaction time. In paper [54] the authors propose fog computing as middleware since it delivers operations to the network's edge effectively and serves delay-sensitive activities. Since creating a task-offloading strategy is complex, this research paper tackles the problem that proposes an intelligent task-offloading framework. They cannot operate for an extended amount of time or could fail to make helpful judgments in complicated scenarios, and the main goal of the task offloading problem is to minimize latency and power usage (Table 5).

Study [55] examined the topic of task offloading delay decrease in a hierarchical fog computing Cloud Radio Access Network (C-RAN) with three tiers of computational services: MEC servers in radio units, MEC servers in distant units, and cloud-based services in centralized units. The receive beamforming vectors, job distribution, processing performance for offloaded tasks on every server, and transmission bandwidth split of front haul links are all optimized by answering the given mixed integer programming issue.

To offer a realistic setting for the evaluation of the suggested task-loading strategies, in study [56] the authors compile a set of Python tasks. In addition, a four-tier structure is developed in this research to identify the appropriate decision-maker for the job at hand. The examiners then classify the issue as a population (evolutionary) game that employs Maynard replicator dynamics. The primary optimization goals in this study are to reduce time and energy consumption. Finally, the authors utilized MATLAB to simulate the suggested strategy, paying particular attention to the usage of accurate values and parameters. As a result, the NP-hard optimization on the character of the

issue has restricted computing resources. In paper [57] the authors presented fog computing as an extra computing model for cloud computing to reduce latency. IoT-based systems run with greater effectiveness when combined with fog computing. When fog is unable to perform an operation owing to insufficient capacity, heavy calculations are offloaded to the cloud. However, understanding when to go from fog to cloud is crucial. The decision to move work from fog to cloud needs to be taken cautiously, and this research provides a solution.

Table 5. Latency offloading strategy in cloud-fog computing

Ref no.	Algorithm	Performance metric	Simulation tool	System	Offloading type	Objective	Demerits
[52]	Elitism-based multi-population Jaya algorithm	Minimise offloading time for latency-sensitive applications while keeping deadline and latency constraints in mind	iFogSim	Multi-user	Binary offloading	To provide a latency-aware offloading technique that takes into account task priorities whilst fulfilling deadlines along with competing QoS restrictions	These activities necessitate the use of increasing resource- and memory-intensive computer nodes for execution
[53]	Adaptive Upper Confidence Boundary (AUCB) algorithm	delay	iFogSim	Multi-user	Fully offloading	To minimize average computation task offloading delay	This algorithm did not satisfy more complex tasks
[54]	Intelligent task offloading model	Bandwidth delay and response time	SFogSim	Multi-user	Multi fog offloading	Less bandwidth equals less delay, which increases reaction time	They cannot function for an extended amount of time and might be unable to arrive at effective conclusions in complex scenarios
[55]	C-RAN network	Delay	Fog-computing network	Multi-user	Binary offloading	To improve the delay performance of task offloading	limited computational capabilities
[56]	Polynomial Parity Arguments on Directed Graphs (PPAD) algorithm	Delay and energy	Python and Matlab	Multi-user	Binary offloading	The basic goals of the task offloading issue are to minimize delay and energy expenditure	The NP-hard character of this issue, as well as the presence of several unfounded presumptions in the offered answers, represents an essential study need in this domain
[57]	MTFCT algorithm	System efficiency and delay	FogSim	Multi-user	Partial offloading	To minimize the delay	To allow task migrations from node to node in the fog computing circumstances, as well as an improved strategy to manage the job on the cloud data center, either work is offloaded from a portable device or any fog node
[58]	Branch-and-bound for MILP	Energy and delay	Matlab2018a	Multi-user	Partial and full offloading	Minimizing the total energy consumption and latency of communication	Mobility of different network components is not considered

In [58] by decreasing the overall power usage of IoT users about communication and computation latency, the authors are putting forth an ideal offloading choice technique and resource allocation scheme in a fog atmosphere. To optimally offload jobs to the fog node, an optimization issue is constructed, with an upgraded branch-and-bound tree proposed for issue assessment. Among the characteristics used by the researchers to assess performance include the average task delay, average power usage per job, and median remaining power per IoT node.

Cloud platforms have already penetrated all sectors of business and left an impression on the economic landscape. Each enterprise is searching for cloud-based business solutions because of the advantages that have a significant impact on a corporation's operational costs. Fog Computing is helping the Cloud Computing platform with increasing its market share and providing technologies depending on the Cloud with a new lease on life.

Latency offloading strategy in IoT-edge-cloud. In paper [59] the authors investigated the workload distribution issue in an IoT edge-cloud computing structure with guaranteed delays and energy efficiency. The researchers created a latency-based task allocation problem that provides the optimum workload distributions over local edge servers, neighbouring edge servers, and the cloud while ensuring minimal power usage and delay. The difficulty is then solved by consuming a delay-based workload allocation (DBWA) method that utilises the Lyapunov drift-plus-penalty theorem. Meanwhile, dynamic traffic patterns of edge and cloud servers, in addition to their diverse computing capacities provide an issue to task allocation. Paper [60] described a block-chain situation whereby secured task offloading may be done by collaborating with edge computing and cloud computing to reduce the usage of energy of the IoT device with delay limitations. In addition, the writers proposed an IoT-Edge-Cloud computing framework for block-chain that leverages both Mobile Cloud Computing (MCC) and MEC, with MEC servers given decreased latency computing services and MCC servers providing more powerful processing capacity. Moreover, they provide an energy-efficient dynamic task offloading (EEDTO) approach by determining the appropriate processing location online, whether on an IoT device, an MEC server, or an MCC server, in order to minimize both power consumption and task response time. The Lyapunov optimization approach is employed to regulate compute and communiqué expenditures for diverse applications, including dynamic alterations to wireless settings. Offloading duties from IoT gadgets to MEC/MCC servers may not be advantageous, particularly if network bandwidth is limited (Table 6).

Table 6. Latency offloading strategy in IoT-edge-cloud

Ref no.	Algorithm	Performance metric	Simulation tool	System	Offloading type	Objective	Demerits
[59]	Delay-base workload allocation (DBWA) algorithm	Transmission power use and network transmission delay	Matlab and C++	-	-	To minimize the drift-plus-penalty, as well as the method's power usage, while providing a per-job granular delay guarantee	The dynamic traffic patterns of edge and cloud servers, along with their diverse computing abilities pose an issue to task allocation
[60]	Energy-efficient dynamic task offloading (EEDTO) algorithm	Delay and energy consumption	Mobile blockchain network	Single user	Partial offloading	With time constraints, the objective is to lower the electrical consumption of the IoT device	Offloading duties from IoT gadgets to MEC/MCC processors might not prove advantageous, particularly if network bandwidth is limited
[61]	Multi-hop cooperative-communication model (MCCM)	QoS, and delay	Matlab	-	-	Aiming for QoS improvements	However, due to resource constraints in the edge server system, an edge-based IIoT may be unable to support resource-intensive activities
[62]	Deep Meta Reinforcement Learning-based Offloading (DMRO)	Delay, minimise computing strain, and enhance job processing efficiency	-	Multi-user	Full offloading	To identify the best offloading system in terms of weighted delay and power usage	When the MEC surroundings shift, the algorithm quickly converges, so only a few learning steps are required to provide low-cost offloading alternatives
[63]	DDMTO (Distributed Deep Meta learning-driven Task Offloading)	CPU energies, executions, network demands, delays, as well as resource utilization, heterogeneities, and overall times are all considered	Python	Multi-user	Partial offloading	To enhance service time and resource consumption	Offloading tasks to the edge/cloud servers might not be ideal, particularly if network bandwidth is constrained

Study [61] investigated the multi-hop computation-offloading issue for the IIoT-edge-cloud computing paradigm by employing a game-theoretical method for distributed computation offloading that is QoS aware. To lower the computational period and power usage of every task, the writers initially investigated the computation-offloading and communication-routing difficulties. The overall challenge is then formulated as a possible game whereby the IIoT devices select their computation-offloading approaches. Secondly, a free-bound technique with a finite enhancement route to a Nash equilibrium is adopted. Finally, the writers created two distributed methods capable of reaching the Nash equilibrium that suggest a multi-hop cooperative messaging network. Meanwhile, due to resource constraints in the edge server, an edge-based IIoT may be unable to support resource-intensive activities.

Paper [62] suggested a Deep Meta Reinforcement Learning-based Offloading (DMRO) method that employs numerous concurrent DNNs along with Q-learning to generate precise offloading judgments in direction to recognize the optimal offloading system that lessens the weighted delay along with power use. The optimum offloading method from the IoT environment may be acquired quickly and flexibly by integrating DL's perceptual capacity, reinforcement learning's decision-making strength, and meta-learning's rapid environment learning ability. After that, to resolve the problems of poor portability and ensure that DNNs are employed for creating successful and productive offloading decisions, study [63] offer DDMTO (Distributed Deep Meta learning-driven Task Offloading). The BP method computes the outputs of these networks utilizing inputs from hidden layers. Based on discrepancies, errors are tracked from intended outputs to hidden layers and from hidden layers to input layers. Neuron weights alter when the flow returns. Epochs are cycles that travel from inputs to outputs and back.

3. Problem Statement. The researchers mentioned here have provided major improvements to task offloading in cloud, edge, and fog computing.

- If there is an excessive amount of task-offloading consumers, certain offloaded processes require waiting for sufficient processing capacity, incurring a delay. The waiting time for task processing at the server can't be overlooked in this scenario and must be considered.

- Task offloading in multi-user systems in MEC ought to be investigated, since balancing edge servers to optimal server utilization hasn't been well investigated in either binary or partial offloading modes.

- Moreover, there is a delay in resource provisioning for an edge or cloud, such as the seconds or minutes it takes a cloud to activate a virtual

machine instance. Hence, this delay in task offloading could lead to violations of QoS standards, such as response times.

- Furthermore, edge-cloud computing necessitates the assessment of provisioning delay, as well as task offloading which is aware of the resource provisioning delay. The calculation of provisioning delay is complex since there are numerous aspects to consider, including the heterogeneity of the resource collection, the software required for offloaded activities, network configuration, time of day, location of edge or cloud, and furthermore.

- To overcome the above-mentioned consequences we provided a suggestion which is discussed in the following section.

4. Objectives.

- In cloud computing, offloading strategies can accelerate the computation of certain parallel ML methods by leveraging their high degree of parallelism, hence reducing latency.

- Furthermore, DL algorithms are extremely effective in addressing the inherent difficulties of edge-cloud computing platforms, where neural network algorithms may decrease multiplication processes during model solutions, also accelerate the method of convergence.

- Various optimization algorithms are introduced to minimize latency and convergence time, hence expediting offloading choices. In this manner, we plan to assess the effectiveness of procedures when offering time-sensitive operations with preset deadlines.

- As a result, we want to create a unique latency-aware intelligent task offloading strategy for edge or cloud computing as a component of our next project.

5. Future Directions. This study proposes some open directions for addressing the latency restrictions in cloud-edge-fog computing.

- As discussed in the overview, the division of data is a critical technique for decreasing latency in complex heterogeneous surroundings. Anyway, because of the variety of input data structures in actual applications, various division techniques are required to improve or optimize system efficiency. Furthermore, the information might be specifically split into distinct properties including size. The optimization may therefore be framed to determine the ideal amount of data subsets and related data subset sizes for optimizing system efficiency.

- A novel swarm-based optimization technique is needed to consider the average metrics such as queue length and latency.

- In addition, traditional as well as classic logic is an intelligent system suitable for being used in those revolutionized sectors where decision-making help is required; consequently, it may be an effective

approach to keep up the existing research conducted with the fog-cloud job offloading technique.

– Work to come may collaborate on local, edge, and cloud processing resources to improve performance even more.

6. Conclusion. A complete study of the system's efficiency with regard to latency in cloud, edge, and fog computing is one of the prospective research. In this research, we present a strategy for detecting associated research in edge-cloud-fog computing based on task type, offloading methodology, and purpose. After that, we thoroughly examine previously published studies that are related to task offloading. Due to investigations on latency-aware task offloading in edge-cloud computing, several challenges must be investigated before edge-cloud computation may be utilized for providing services. As a consequence, we discussed a few of these difficulties, in addition to possible additional research on task offloading latency in edge-cloud-fog computing. For academics, and industry groups interested in edge clouds, we trust that our survey work is beneficial.

References

1. Wang F., Zhu M., Wang M., Khosravi M.R., Ni Q., Yu S., Qi L. 6G-enabled short-term forecasting for large-scale traffic flow in massive IoT based on time-aware locality-sensitive hashing. *IEEE Internet of Things Journal*. 2020. vol. 8. no. 7. pp. 5321–5331.
2. Wei D., Ning H., Shi F., Wan Y., Xu J., Yang S., Zhu L. Dataflow management in the internet of things: Sensing, control, and security. *Tsinghua Science and Technology*. 2021. vol. 26. no. 6. pp. 918–930.
3. Zheng T., Wan J., Zhang J., Jiang C., Jia G. A survey of computation offloading in edge computing. In *2020 International Conference on Computer, Information and Telecommunication Systems (CITS)*. IEEE, 2020. pp. 1–6.
4. Saeik F., Avgeris M., Spatharakis D., Santi N., Dechouniotis D., Violos J., Papavassiliou S. Task offloading in Edge and Cloud Computing: A survey on mathematical, artificial intelligence and control theory solutions. *Computer Networks*. 2021. vol. 195. no.108177.
5. Zhao T., Zhou S., Guo X., Zhao Y., Niu Z. A cooperative scheduling scheme of local cloud and internet cloud for delay-aware mobile cloud computing. *IEEE globecom workshops (GC Wkshps)*. IEEE, 2015. pp. 1–6.
6. Xu F., Yang W., Li H. Computation offloading algorithm for cloud robot based on improved game theory. *Computers & Electrical Engineering*. 2020. vol. 87. no. 106764.
7. Shakarami A., Ghobaei-Arani M., Masdari M., Hosseinzadeh M. A survey on the computation offloading approaches in mobile edge/cloud computing environment: a stochastic-based perspective. *Journal of Grid Computing*. 2020. vol. 18. pp. 639–671.
8. Guo S., Zeng D., Gu L., Luo J. When green energy meets cloud radio access network: Joint optimization towards brown energy minimization. *Mobile Networks and Applications*. 2019. vol. 24. pp. 962–970.

9. Dai H.N., Wong R.C.W., Wang H., Zheng Z., Vasilakos A.V. Big data analytics for large-scale wireless networks: Challenges and opportunities. *ACM Computing Surveys (CSUR)*. 2019. vol. 52. no. 5. pp. 1–36.
10. Hong C.H., Varghese, B. Resource management in fog/edge computing: a survey on architectures, infrastructure, and algorithms. *ACM Computing Surveys (CSUR)*. 2019. vol. 52. no. 5. pp. 1–36.
11. Xu Z., Liang W., Jia M., Huang M., Mao G. Task offloading with network function requirements in a mobile edge-cloud network. *IEEE Transactions on Mobile Computing*. 2018. vol. 18. no. 11. pp. 2672–2685.
12. Ren J., Zhang D., He S., Zhang Y., Li T. A survey on end-edge-cloud orchestrated network computing paradigms: Transparent computing, mobile edge computing, fog computing, and cloudlet. *ACM Computing Surveys (CSUR)*. 2019. vol. 52. no. 6. pp. 1–36.
13. Zhang Z., Li C., Peng S., Pei X. A new task offloading algorithm in edge computing. *EURASIP Journal on Wireless Communications and Networking*. 2021. vol. 2021. pp. 1–21.
14. You C., Huang K., Chae H., Kim B.H. Energy-efficient resource allocation for mobile-edge computation offloading. *IEEE Transactions on Wireless Communications*. 2016. vol. 16. no. 3. pp. 1397–1411.
15. De D., Mukherjee A., Guha Roy D. Power and delay efficient multilevel offloading strategies for mobile cloud computing. *Wireless Personal Communications*. 2020. vol. 112. pp. 2159–2186.
16. Sun M., Xu X., Tao X., Zhang P. Large-scale user-assisted multi-task online offloading for latency reduction in D2D-enabled heterogeneous networks. *IEEE Transactions on Network Science and Engineering*. 2020. vol. 7. no. 4. pp. 2456–2467.
17. Niu H., Wang L., Du K., Lu Z., Wen X., Liu Y. A pipelining task offloading strategy via delay-aware multi-agent reinforcement learning in Cybertwin-enabled 6G network. *Digital Communications and Networks*. 2023. DOI: 10.1016/j.dcan.2023.04.004.
18. Liu H., Niu Z., Du J., Lin X. Genetic algorithm for delay efficient computation offloading in dispersed computing. *Ad Hoc Networks*. 2023. vol. 142. no. 103109.
19. Mirza M.A., Yu J., Raza S., Krichen M., Ahmed M., Khan W.U., Rabie K., Shongwe T. DRL-assisted delay optimized task offloading in Automotive-Industry 5.0 based VECNs. *Journal of King Saud University-Computer and Information Sciences*. 2023. vol. 35(6). no. 101512. DOI: 10.1016/j.jksuci.2023.02.013.
20. Li X., Ye B. Latency-Aware Computation Offloading for 5G Networks in Edge Computing. *Security and Communication Networks*. 2021. vol. 2021. pp. 1–15.
21. Cozzolino V., Tonetto L., Mohan N., Ding A.Y., Ott J. Nimbus: Towards latency-energy efficient task offloading for ar services. *IEEE Transactions on Cloud Computing*. 2023. vol. 11. no. 2. pp. 1530–1545. DOI: 10.1109/TCC.2022.3146615.
22. Liu C.F., Bennis M., Debbah M., Poor H.V. Dynamic task offloading and resource allocation for ultra-reliable low-latency edge computing. *IEEE Transactions on Communications*. 2019. vol. 67. no. 6. pp. 4132–4150.
23. Zhang H., Yang Y., Huang X., Fang C., Zhang P. Ultra-low latency multi-task offloading in mobile edge computing. *IEEE Access*, 2021. vol. 9. pp. 32569–32581.
24. Yang T., Feng H., Gao S., Jiang Z., Qin M., Cheng N., Bai L. Two-stage offloading optimization for energy–latency tradeoff with mobile edge computing in maritime Internet of Things. *IEEE Internet of Things Journal*. 2019. vol. 7. no. 7. pp. 5954–5963.

25. Shu C., Zhao Z., Han Y., Min G., Duan H. Multi-user offloading for edge computing networks: A dependency-aware and latency-optimal approach. *IEEE Internet of Things Journal*. 2019. vol. 7. no. 3. pp. 1678–1689.
26. Gu X., Ji C., Zhang G. Energy-optimal latency-constrained application offloading in mobile-edge computing. *Sensors*. 2020. vol. 20(11). no. 3064.
27. Liu S., Yu Y., Guo L., Yeoh P.L., Vucetic B., Li Y. Adaptive delay-energy balanced partial offloading strategy in Mobile Edge Computing networks. *Digital Communications and Networks*. 2022. DOI: 10.1016/j.dcan.2022.05.029.
28. Zhang Y., Chen J., Zhou Y., Yang L., He B., Yang Y. Dependent task offloading with energy-latency tradeoff in mobile edge computing. *IET Communications*. 2022. vol. 16. no. 17. pp. 1993–2001.
29. Li Y., Wang T., Wu Y., Jia W. Optimal dynamic spectrum allocation-assisted latency minimization for multiuser mobile edge computing. *Digital Communications and Networks*. 2022. vol. 8. no. 3. pp. 247–256.
30. Wang M., Wu T., Ma T., Fan X., Ke M. Users' experience matter: Delay sensitivity-aware computation offloading in mobile edge computing. *Digital Communications and Networks*. 2022. vol. 8. no. 6. pp. 955–963.
31. Elgendy I.A., Zhang W.Z., Liu C.Y., Hsu C.H. An efficient and secured framework for mobile cloud computing. *IEEE Transactions on Cloud Computing*. 2018. vol. 9. no. 1. pp. 79–87.
32. Tyagi H., Kumar R. Cloud computing for IoT. *Internet of Things (IoT) Concepts and Applications*. 2020. pp. 25–41.
33. Cong P., Zhou J., Li L., Cao K., Wei T., Li K. A survey of hierarchical energy optimization for mobile edge computing: A perspective from end devices to the cloud. *ACM Computing Surveys (CSUR)*. 2020. vol. 53. no. 2. pp. 1–44.
34. Elgendy I.A., Zhang W., Tian Y.C., Li K. Resource allocation and computation offloading with data security for mobile edge computing. *Future Generation Computer Systems*. 2019. vol. 100. pp. 531–541.
35. Zhang W.Z., Elgendy I.A., Hammad M., Iliyasu A.M., Du X., Guizani M., Abd el-Latif A.A. Secure and optimized load balancing for multitier IoT and edge-cloud computing systems. *IEEE Internet of Things Journal*. 2021. vol. 8. no. 10. pp. 8119–8132.
36. Elgendy I.A., Zhang W.Z., Zeng Y., He H., Tian Y.C., Yang Y. Efficient and secure multi-user multi-task computation offloading for mobile-edge computing in mobile IoT networks. *IEEE Transactions on Network and Service Management*. 2020. vol. 17. no. 4. pp. 2410–2422.
37. Mahmud R., Ramamohanarao K., Buyya R. Application management in fog computing environments: A taxonomy, review and future directions. *ACM Computing Surveys (CSUR)*. 2020. vol. 53. no. 4. pp. 1–43.
38. Helbig M., Deb K., Engelbrecht A. Key challenges and future directions of dynamic multi-objective optimisation. *IEEE Congress on Evolutionary Computation (CEC)*. IEEE, 2016. pp. 1256–1261.
39. Almutairi J., Aldossary M. A novel approach for IoT tasks offloading in edge-cloud environments. *Journal of Cloud Computing*. 2021. vol. 10(1). pp. 1–19.
40. Almutairi J., Aldossary M., Alharbi H.A., Yosuf B.A., Elmirghani J.M. Delay-optimal task offloading for UAV-enabled edge-cloud computing systems. *IEEE Access*. 2022. vol. 10. pp. 51575–51586.
41. Wang Y., Wang L., Zheng R., Zhao X., Liu M. Latency-optimal computational offloading strategy for sensitive tasks in smart homes. *Sensors*. 2021. vol. 21(7). no. 2347.

42. Ren J., Yu G., He Y., Li G.Y. Collaborative cloud and edge computing for latency minimization. *IEEE Transactions on Vehicular Technology*. 2019. vol. 68. no. 5. pp. 5031–5044.
43. Lakhan A., Mohammed M.A., Abdulkareem K.H., Jaber M.M., Nedoma J., Martinek R., Zmij P. Delay optimal schemes for Internet of Things applications in heterogeneous edge cloud computing networks. *Sensors*. 2022. vol. 22(16). no. 5937.
44. AlShathri S.L., Hassan D.S., Chelloug S.A. Latency-Aware Dynamic Second Offloading Service in SDN-Based Fog Architecture. *CMC-Computers Materials and Continua*. 2023. vol. 75. no. 1. pp. 1501–1526.
45. Kaur P., Mehta S. Improvement of Task Offloading for Latency Sensitive Tasks in Fog Environment. *Energy Conservation Solutions for Fog-Edge Computing Paradigms*. 2022. pp. 49–63.
46. Mukherjee M., Kumar V., Kumar S., Matamy R., Mavromoustakis C.X., Zhang Q., Shojafar M., Mastorakis G. Computation offloading strategy in heterogeneous fog computing with energy and delay constraints. *IEEE International Conference on Communications (ICC)*. IEEE, 2020. pp. 1–5. DOI: 10.1109/ICC40277.2020.9148852.
47. Tran-Dang H., Kim D.S. Dynamic collaborative task offloading for delay minimization in the heterogeneous fog computing systems. *Journal of Communications and Networks*. 2023. vol. 25. no. 2. pp. 244–252. DOI: 10.23919/JCN.2023.000008.
48. Tran-Dang H., Kim D.S. FRATO: Fog resource based adaptive task offloading for delay-minimizing IoT service provisioning. *IEEE Transactions on Parallel and Distributed Systems*. 2021. vol. 32. no. 10. pp. 2491–2508.
49. Kishor A., Chakraborty C. Task offloading in fog computing for using smart ant colony optimization. *Wireless personal communications*. 2021. pp. 1–22.
50. Ren Q., Liu K., Zhang L. Multi-objective optimization for task offloading based on network calculus in fog environments. *Digital Communications and Networks*. 2022. vol. 8(5). pp. 825–833.
51. Tran-Dang H., Kim D.S. Distributed Computation Offloading Framework for Fog Computing Networks. *Cooperative and Distributed Intelligent Computation in Fog Computing: Concepts, Architectures, and Frameworks*. 2023. pp. 133–155.
52. Chakraborty C., Mishra K., Majhi S.K., Bhuyan H.K. Intelligent Latency-aware tasks prioritization and offloading strategy in Distributed Fog-Cloud of Things. *IEEE Transactions on Industrial Informatics*. 2022. vol. 19(2). pp. 2099–2106.
53. Cui K., Lin B., Sun W., Sun W. Learning-based task offloading for marine fog-cloud computing networks of USV cluster. *Electronics*. 2019. vol. 8(11). no. 1287.
54. Bukhari M.M., Ghazal T.M., Abbas S., Khan M.A., Farooq U., Wahbah H., Ahmad M., Adnan, K M. An intelligent proposed model for task offloading in fog-cloud collaboration using logistics regression. *Computational Intelligence and Neuroscience*. 2022. vol. 2022. DOI: 10.1155/2022/3606068.
55. Pan Y., Jiang H., Zhu H., Wang J. Latency minimization for task offloading in hierarchical fog-computing C-RAN networks. *IEEE International Conference on Communications (ICC)*. IEEE, 2020. pp. 1–6.
56. Mahini H., Rahmani A.M., Mousavirad S.M. An evolutionary game approach to IoT task offloading in fog-cloud computing. *The Journal of Supercomputing*. 2021. vol. 77. pp. 5398–5425.
57. Jindal R., Kumar N., Nirwan H. MTFCT: A task offloading approach for fog computing and cloud computing. *10th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*. IEEE, 2020. pp. 145–149.

58. Jain V., Kumar B. Optimal task offloading and resource allotment towards fog-cloud architecture. 11th International Conference on Cloud Computing, Data Science and Engineering (Confluence). IEEE. 2021. pp. 233–238.
59. Guo M., Li L., Guan Q. Energy-efficient and delay-guaranteed workload allocation in IoT-edge-cloud computing systems. IEEE Access. 2019. vol. 7. pp. 78685–78697.
60. Wu H., Wolter K., Jiao P., Deng Y., Zhao Y., Xu M. EEDTO: An energy-efficient dynamic task offloading algorithm for blockchain-enabled IoT-edge-cloud orchestrated computing. IEEE Internet of Things Journal. 2020. vol. 8. no. 4. pp. 2163–2176.
61. Hong Z., Chen W., Huang H., Guo S., Zheng Z. Multi-hop cooperative computation offloading for industrial IoT-edge-cloud computing environments. IEEE Transactions on Parallel and Distributed Systems. 2019. vol. 30. no. 12. pp. 2759–2774.
62. Qu G., Wu H., Li R., Jiao P. DMRO: A deep meta reinforcement learning-based task offloading framework for edge-cloud computing. IEEE Transactions on Network and Service Management. 2021. vol. 18. no. 3. pp. 3448–3459.
63. Gali M., Mahankali A. A Distributed Deep Meta Learning based Task Offloading Framework for Smart City Internet of Things with Edge-Cloud Computing. Journal of Internet Services and Information Security. 2022. vol. 12. no. 4. pp. 224–237.

Swapna B — Ph.D., Employee, Koneru Lakshmaiah Education Foundation (Deemed to be University), Vaddeshwaram. Research interests: computer science and engineering. The number of publications — 2. swapnaswapb@gmail.com; Green Fields, Vaddeswaram, 522302, Guntur, India; office phone: +91(8645)350-0200.

Divya V — Ph.D., Dr.Sci., Associate professor, Koneru Lakshmaiah Education Foundation (Deemed to be University), Vaddeshwaram. Research interests: network security, cloud computing. The number of publications — 6. divya.movva@kluniversity.in; Green Fields, Vaddeswaram, 522302, Guntur, Russia; office phone: +91(8645)350-0200.

Б. СВАПНА, В. ДИВЬЯ
**ИНТЕЛЛЕКТУАЛЬНАЯ СХЕМА РАСПРЕДЕЛЕНИЕ ЗАДАЧ С
УЧЕТОМ ЗАДЕРЖЕК ВЫЧИСЛЕНИЙ В EDGE-FOG-CLOUD –
ОБЗОР**

Свапна Б., Дивья В. Интеллектуальная схема распределения задач с учетом задержек вычислений в Edge-Fog-Cloud – обзор.

Аннотация. Огромный объем данных, создаваемых процедурами Интернета вещей, требует вычислительной мощности и места для хранения, предоставляемого облачными, периферийными и туманными вычислительными системами. Каждый из этих способов вычислений имеет как преимущества, так и недостатки. Облачные вычисления улучшают хранение информации и вычислительные возможности, одновременно увеличивая задержку соединения. Периферийные и туманные вычисления предлагают аналогичные преимущества с уменьшенной задержкой, но имеют ограниченное хранилище, емкость и покрытие. Первоначально оптимизация применялась для решения проблемы сброса трафика. И наоборот, традиционная оптимизация не может удовлетворить жесткие требования к задержке принятия решений в сложных системах, варьирующейся от миллисекунд до долей секунды. В результате алгоритмы машинного обучения, особенно обучение с подкреплением, набирают популярность, поскольку они могут быстро решать проблемы разгрузки в динамических ситуациях, включающих определенные неопознанные данные. Мы проводим анализ литературы, чтобы изучить различные методы, используемые для решения этой интеллектуальной задачи по разгрузке задач с учетом задержек для облачных, периферийных и туманных вычислений. Уроки, полученные в результате этих исследований, затем представлены в настоящем отчете. Наконец, мы определяем некоторые дополнительные возможности для изучения и проблемы, которые необходимо преодолеть, чтобы достичь минимальной задержки в системе разгрузки задач.

Ключевые слова: разгрузка задач, облачные вычисления, периферийные вычисления, туманные вычисления, Интернет вещей, задержка.

Литература

1. Wang F., Zhu M., Wang M., Khosravi M.R., Ni Q., Yu S., Qi L. 6G-enabled short-term forecasting for large-scale traffic flow in massive IoT based on time-aware locality-sensitive hashing. *IEEE Internet of Things Journal*. 2020. vol. 8. no. 7. pp. 5321–5331.
2. Wei D., Ning H., Shi F., Wan Y., Xu J., Yang S., Zhu L. Dataflow management in the internet of things: Sensing, control, and security. *Tsinghua Science and Technology*. 2021. vol. 26. no. 6. pp. 918–930.
3. Zheng T., Wan J., Zhang J., Jiang C., Jia G. A survey of computation offloading in edge computing. In *2020 International Conference on Computer, Information and Telecommunication Systems (CITS)*. IEEE, 2020. pp. 1–6.
4. Saeik F., Avgeris M., Spatharakis D., Santi N., Dechouniotis D., Violos J., Papavassiliou S. Task offloading in Edge and Cloud Computing: A survey on mathematical, artificial intelligence and control theory solutions. *Computer Networks*. 2021. vol. 195. no.108177.
5. Zhao T., Zhou S., Guo X., Zhao Y., Niu Z. A cooperative scheduling scheme of local cloud and internet cloud for delay-aware mobile cloud computing. *IEEE globecom workshops (GC Wkshps)*. IEEE, 2015. pp. 1–6.

6. Xu F., Yang W., Li H. Computation offloading algorithm for cloud robot based on improved game theory. *Computers & Electrical Engineering*. 2020. vol. 87. no. 106764.
7. Shakarami A., Ghobaei-Arani M., Masdari M., Hosseinzadeh M. A survey on the computation offloading approaches in mobile edge/cloud computing environment: a stochastic-based perspective. *Journal of Grid Computing*. 2020. vol. 18. pp. 639–671.
8. Guo S., Zeng D., Gu L., Luo J. When green energy meets cloud radio access network: Joint optimization towards brown energy minimization. *Mobile Networks and Applications*. 2019. vol. 24. pp. 962–970.
9. Dai H.N., Wong R.C.W., Wang H., Zheng Z., Vasilakos A.V. Big data analytics for large-scale wireless networks: Challenges and opportunities. *ACM Computing Surveys (CSUR)*. 2019. vol. 52. no. 5. pp. 1–36.
10. Hong C.H., Varghese, B. Resource management in fog/edge computing: a survey on architectures, infrastructure, and algorithms. *ACM Computing Surveys (CSUR)*. 2019. vol. 52. no. 5. pp. 1–36.
11. Xu Z., Liang W., Jia M., Huang M., Mao G. Task offloading with network function requirements in a mobile edge-cloud network. *IEEE Transactions on Mobile Computing*. 2018. vol. 18. no. 11. pp. 2672–2685.
12. Ren J., Zhang D., He S., Zhang Y., Li T. A survey on end-edge-cloud orchestrated network computing paradigms: Transparent computing, mobile edge computing, fog computing, and cloudlet. *ACM Computing Surveys (CSUR)*. 2019. vol. 52. no. 6. pp. 1–36.
13. Zhang Z., Li C., Peng S., Pei X. A new task offloading algorithm in edge computing. *EURASIP Journal on Wireless Communications and Networking*. 2021. vol. 2021. pp. 1–21.
14. You C., Huang K., Chae H., Kim B.H. Energy-efficient resource allocation for mobile-edge computation offloading. *IEEE Transactions on Wireless Communications*. 2016. vol. 16. no. 3. pp. 1397–1411.
15. De D., Mukherjee A., Guha Roy D. Power and delay efficient multilevel offloading strategies for mobile cloud computing. *Wireless Personal Communications*. 2020. vol. 112. pp. 2159–2186.
16. Sun M., Xu X., Tao X., Zhang P. Large-scale user-assisted multi-task online offloading for latency reduction in D2D-enabled heterogeneous networks. *IEEE Transactions on Network Science and Engineering*. 2020. vol. 7. no. 4. pp. 2456–2467.
17. Niu H., Wang L., Du K., Lu Z., Wen X., Liu Y. A pipelining task offloading strategy via delay-aware multi-agent reinforcement learning in Cybertwin-enabled 6G network. *Digital Communications and Networks*. 2023. DOI: 10.1016/j.dcan.2023.04.004.
18. Liu H., Niu Z., Du J., Lin X. Genetic algorithm for delay efficient computation offloading in dispersed computing. *Ad Hoc Networks*. 2023. vol. 142. no. 103109.
19. Mirza M.A., Yu J., Raza S., Krichen M., Ahmed M., Khan W.U., Rabie K., Shongwe T. DRL-assisted delay optimized task offloading in Automotive-Industry 5.0 based VECNs. *Journal of King Saud University-Computer and Information Sciences*. 2023. vol. 35(6). no. 101512. DOI: 10.1016/j.jksuci.2023.02.013.
20. Li X., Ye B. Latency-Aware Computation Offloading for 5G Networks in Edge Computing. *Security and Communication Networks*. 2021. vol. 2021. pp. 1–15.
21. Cozzolino V., Tonetto L., Mohan N., Ding A.Y., Ott J. Nimbus: Towards latency-energy efficient task offloading for ar services. *IEEE Transactions on Cloud Computing*. 2023. vol. 11. no. 2. pp. 1530–1545. DOI: 10.1109/TCC.2022.3146615.

22. Liu C.F., Bennis M., Debbah M., Poor H.V. Dynamic task offloading and resource allocation for ultra-reliable low-latency edge computing. *IEEE Transactions on Communications*. 2019. vol. 67. no. 6. pp. 4132–4150.
23. Zhang H., Yang Y., Huang X., Fang C., Zhang P. Ultra-low latency multi-task offloading in mobile edge computing. *IEEE Access*, 2021. vol. 9. pp. 32569–32581.
24. Yang T., Feng H., Gao S., Jiang Z., Qin M., Cheng N., Bai L. Two-stage offloading optimization for energy–latency tradeoff with mobile edge computing in maritime Internet of Things. *IEEE Internet of Things Journal*. 2019. vol. 7. no. 7. pp. 5954–5963.
25. Shu C., Zhao Z., Han Y., Min G., Duan H. Multi-user offloading for edge computing networks: A dependency-aware and latency-optimal approach. *IEEE Internet of Things Journal*. 2019. vol. 7. no. 3. pp. 1678–1689.
26. Gu X., Ji C., Zhang G. Energy-optimal latency-constrained application offloading in mobile-edge computing. *Sensors*. 2020. vol. 20(11). no. 3064.
27. Liu S., Yu Y., Guo L., Yeoh P.L., Vucetic B., Li Y. Adaptive delay-energy balanced partial offloading strategy in Mobile Edge Computing networks. *Digital Communications and Networks*. 2022. DOI: 10.1016/j.dcan.2022.05.029.
28. Zhang Y., Chen J., Zhou Y., Yang L., He B., Yang Y. Dependent task offloading with energy-latency tradeoff in mobile edge computing. *IET Communications*. 2022. vol. 16. no. 17. pp. 1993–2001.
29. Li Y., Wang T., Wu Y., Jia W. Optimal dynamic spectrum allocation-assisted latency minimization for multiuser mobile edge computing. *Digital Communications and Networks*. 2022. vol. 8. no. 3. pp. 247–256.
30. Wang M., Wu T., Ma T., Fan X., Ke M. Users' experience matter: Delay sensitivity-aware computation offloading in mobile edge computing. *Digital Communications and Networks*. 2022. vol. 8. no. 6. pp. 955–963.
31. Elgendy I.A., Zhang W.Z., Liu C.Y., Hsu C.H. An efficient and secured framework for mobile cloud computing. *IEEE Transactions on Cloud Computing*. 2018. vol. 9. no. 1. pp. 79–87.
32. Tyagi H., Kumar R. Cloud computing for IoT. *Internet of Things (IoT) Concepts and Applications*. 2020. pp. 25–41.
33. Cong P., Zhou J., Li L., Cao K., Wei T., Li K. A survey of hierarchical energy optimization for mobile edge computing: A perspective from end devices to the cloud. *ACM Computing Surveys (CSUR)*. 2020. vol. 53. no. 2. pp. 1–44.
34. Elgendy I.A., Zhang W., Tian Y.C., Li K. Resource allocation and computation offloading with data security for mobile edge computing. *Future Generation Computer Systems*. 2019. vol. 100. pp. 531–541.
35. Zhang W.Z., Elgendy I.A., Hammad M., Ilyasu A.M., Du X., Guizani M., Abd el-Latif A.A. Secure and optimized load balancing for multitier IoT and edge-cloud computing systems. *IEEE Internet of Things Journal*. 2021. vol. 8. no. 10. pp. 8119–8132.
36. Elgendy I.A., Zhang W.Z., Zeng Y., He H., Tian Y.C., Yang Y. Efficient and secure multi-user multi-task computation offloading for mobile-edge computing in mobile IoT networks. *IEEE Transactions on Network and Service Management*. 2020. vol. 17. no. 4. pp. 2410–2422.
37. Mahmud R., Ramamohanarao K., Buyya R. Application management in fog computing environments: A taxonomy, review and future directions. *ACM Computing Surveys (CSUR)*. 2020. vol. 53. no. 4. pp. 1–43.
38. Helbig M., Deb K., Engelbrecht A. Key challenges and future directions of dynamic multi-objective optimisation. *IEEE Congress on Evolutionary Computation (CEC)*. IEEE, 2016. pp. 1256–1261.

39. Almutairi J., Aldossary M. A novel approach for IoT tasks offloading in edge-cloud environments. *Journal of Cloud Computing*. 2021. vol. 10(1). pp. 1–19.
40. Almutairi J., Aldossary M., Alharbi H.A., Yosuf B.A., Elmirghani J.M. Delay-optimal task offloading for UAV-enabled edge-cloud computing systems. *IEEE Access*. 2022. vol. 10. pp. 51575–51586.
41. Wang Y., Wang L., Zheng R., Zhao X., Liu M. Latency-optimal computational offloading strategy for sensitive tasks in smart homes. *Sensors*. 2021. vol. 21(7). no. 2347.
42. Ren J., Yu G., He Y., Li G.Y. Collaborative cloud and edge computing for latency minimization. *IEEE Transactions on Vehicular Technology*. 2019. vol. 68. no. 5. pp. 5031–5044.
43. Lakhan A., Mohammed M.A., Abdulkareem K.H., Jaber M.M., Nedoma J., Martinek R., Zmij P. Delay optimal schemes for Internet of Things applications in heterogeneous edge cloud computing networks. *Sensors*. 2022. vol. 22(16). no. 5937.
44. AlShathri S.I., Hassan D.S., Chelloug S.A. Latency-Aware Dynamic Second Offloading Service in SDN-Based Fog Architecture. *CMC-Computers Materials and Continua*. 2023. vol. 75. no. 1. pp. 1501–1526.
45. Kaur P., Mehta S. Improvement of Task Offloading for Latency Sensitive Tasks in Fog Environment. *Energy Conservation Solutions for Fog-Edge Computing Paradigms*. 2022. pp. 49–63.
46. Mukherjee M., Kumar V., Kumar S., Matamy R., Mavromoustakis C.X., Zhang Q., Shojafar M., Mastorakis G. Computation offloading strategy in heterogeneous fog computing with energy and delay constraints. *IEEE International Conference on Communications (ICC)*. IEEE. 2020. pp. 1–5. DOI: 10.1109/ICC40277.2020.9148852.
47. Tran-Dang H., Kim D.S. Dynamic collaborative task offloading for delay minimization in the heterogeneous fog computing systems. *Journal of Communications and Networks*. 2023. vol. 25. no. 2. pp. 244–252. DOI: 10.23919/JCN.2023.000008.
48. Tran-Dang H., Kim D.S. FRATO: Fog resource based adaptive task offloading for delay-minimizing IoT service provisioning. *IEEE Transactions on Parallel and Distributed Systems*. 2021. vol. 32. no. 10. pp. 2491–2508.
49. Kishor A., Chakarbarti C. Task offloading in fog computing for using smart ant colony optimization. *Wireless personal communications*. 2021. pp. 1–22.
50. Ren Q., Liu K., Zhang L. Multi-objective optimization for task offloading based on network calculus in fog environments. *Digital Communications and Networks*. 2022. vol. 8(5). pp. 825–833.
51. Tran-Dang H., Kim D.S. Distributed Computation Offloading Framework for Fog Computing Networks. *Cooperative and Distributed Intelligent Computation in Fog Computing: Concepts, Architectures, and Frameworks*. 2023. pp. 133–155.
52. Chakraborty C., Mishra K., Majhi S.K., Bhuyan H.K. Intelligent Latency-aware tasks prioritization and offloading strategy in Distributed Fog-Cloud of Things. *IEEE Transactions on Industrial Informatics*. 2022. vol. 19(2). pp. 2099–2106.
53. Cui K., Lin B., Sun W., Sun W. Learning-based task offloading for marine fog-cloud computing networks of USV cluster. *Electronics*. 2019. vol. 8(11). no. 1287.
54. Bukhari M.M., Ghazal T.M., Abbas S., Khan M.A., Farooq U., Wabba H., Ahmad M., Adnan, K M. An intelligent proposed model for task offloading in fog-cloud collaboration using logistics regression. *Computational Intelligence and Neuroscience*. 2022. vol. 2022. DOI: 10.1155/2022/3606068.
55. Pan Y., Jiang H., Zhu H., Wang J. Latency minimization for task offloading in hierarchical fog-computing C-RAN networks. *IEEE International Conference on Communications (ICC)*. IEEE, 2020. pp. 1–6.

56. Mahini H., Rahmani A.M., Mousavirad S.M. An evolutionary game approach to IoT task offloading in fog-cloud computing. *The Journal of Supercomputing*. 2021. vol. 77. pp. 5398–5425.
57. Jindal R., Kumar N., Nirwan H. MTFCT: A task offloading approach for fog computing and cloud computing. 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence). IEEE, 2020. pp. 145–149.
58. Jain V., Kumar B. Optimal task offloading and resource allotment towards fog-cloud architecture. 11th International Conference on Cloud Computing, Data Science and Engineering (Confluence). IEEE. 2021. pp. 233–238.
59. Guo M., Li L., Guan Q. Energy-efficient and delay-guaranteed workload allocation in IoT-edge-cloud computing systems. *IEEE Access*. 2019. vol. 7. pp. 78685–78697.
60. Wu H., Wolter K., Jiao P., Deng Y., Zhao Y., Xu M. EEDTO: An energy-efficient dynamic task offloading algorithm for blockchain-enabled IoT-edge-cloud orchestrated computing. *IEEE Internet of Things Journal*. 2020. vol. 8. no. 4. pp. 2163–2176.
61. Hong Z., Chen W., Huang H., Guo S., Zheng Z. Multi-hop cooperative computation offloading for industrial IoT-edge-cloud computing environments. *IEEE Transactions on Parallel and Distributed Systems*. 2019. vol. 30. no. 12. pp. 2759–2774.
62. Qu G., Wu H., Li R., Jiao P. DMRO: A deep meta reinforcement learning-based task offloading framework for edge-cloud computing. *IEEE Transactions on Network and Service Management*. 2021. vol. 18. no. 3. pp. 3448–3459.
63. Gali M., Mahamkali A. A Distributed Deep Meta Learning based Task Offloading Framework for Smart City Internet of Things with Edge-Cloud Computing. *Journal of Internet Services and Information Security*. 2022. vol. 12. no. 4. pp. 224–237.

Свапна Б — Ph.D., сотрудник, Образовательный фонд Конеру Лакшмайи (Считается университетом). Область научных интересов: информатика и инженерия. Число научных публикаций — 2. swarnaswapb@gmail.com; Зеленые поля, Ваддесварам, 522302, Гунтур, Индия; р.т.: +91(8645)350-0200.

Дивья В — Ph.D., Dr.Sci., доцент, Образовательный фонд Конеру Лакшмайи (Считается университетом). Область научных интересов: сетевая безопасность, облачные вычисления. Число научных публикаций — 6. divya.movva@kluniversity.in; Зеленые поля, Ваддесварам, 522302, Гунтур, Россия; р.т.: +91(8645)350-0200.

Руководство для авторов

Взаимодействие автора с редакцией осуществляется через личный кабинет на сайте журнала «Информатика и автоматизация» <http://ia.spcras.ru/>. При регистрации авторам рекомендуется заполнить все предложенные поля данных. Подготовка статьи ведется с помощью текстовых редакторов MS Word 2007 и выше или LaTeX. Объем основного текста (до раздела Литература) - от 20 до 30 страниц включительно. Переносы запрещены. Номера страниц не проставляются. Основная часть текста статьи разбивается на разделы, среди которых являются обязательными: введение, хотя бы один «содержательный» раздел и заключение. Допускается также мотивированное содержанием и структурой материал а выделение подразделов. В основную часть опускается помещать рисунки, таблицы, листинги и формулы. Правила их оформления подробно рассмотрены на нашем сайте в разделе «Руководство для авторов».

Author guidelines

Interaction between each potential author and the Editorial board is realized through the personal account on the website of the journal "Informatics and Automation" <http://ia.spcras.ru/>. At the registration the authors are requested to fill out all data fields in the proposed form. The submissions should be prepared using MS Word 2007, LaTeX. The text of the paper in the main part should not exceed 30 pages. Pages are not numbered; hyphenations are not allowed. Certain figures, tables, listings and formulas are allowed in the main section, and their typography is considered in more detail at the journal web.

Signed to print 10.01.2024. Passed for print 01.02.2024.

Printed in Publishing center GUAP.

Address: 67 litera A, B. Morskaya, St. Petersburg, 190000, Russia

Founder and Publisher: SPC RAS.

Address: 39 litera A, 14th Line V.O., St. Peterburg, 199178, Russia.

The journal is registered in the Federal Service for Supervision of Communications, Information Technology, and Mass Media, Registration Certificate (registration number) ПИ № ФС77-79228 dated September 25, 2020 Subscription Index П5513, Russian Post Catalog

Подписано к печати 10.01.2024. Дата выхода в свет 01.02.2024.

Формат 60×90 1/16. Усл. печ. л. 18,5. Заказ № 5. Тираж 300 экз., цена свободная.

Отпечатано в Редакционно-издательском центре ГУАП.

Адрес типографии: Б. Морская, д. 67, лит. А, г. Санкт-Петербург, 190000, Россия

Учредитель и издатель: СПб ФИЦ РАН.

Адрес учредителя и издателя: 14-я линия В.О., д. 39, лит. А, г. Санкт-Петербург, 199178, Россия

Журнал зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций, свидетельство о регистрации (регистрационный номер) ПИ № ФС77-79228 от 25 сентября 2020 г.

Подписной индекс П5513 по каталогу «Почта России»