

ISSN 2713-3192
DOI 10.15622/ia.2022.21.6
<http://ia.spcras.ru>

ТОМ 21 № 6

**ИНФОРМАТИКА
И АВТОМАТИЗАЦИЯ**

**INFORMATICS
AND AUTOMATION**



СПб ФИЦ РАН

**Санкт-Петербург
2022**



СПИИРАН

INFORMATICS AND AUTOMATION

Volume 21 № 6, 2022

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
N. P. Veselkin	Prof., Dr. Sci., Academician of RAS, St. Petersburg, Russia
I. A. Kalyaev	Prof., Dr. Sci., Academician of RAS, Taganrog, Russia
Yu. A. Merkuruyev	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

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, 2022

ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

Том 21 № 6 , 2022

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
Н. П. Веселкин	академик РАН, д-р мед. наук, проф., Санкт-Петербург, РФ
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. Сойфер	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. Кайя	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, Аизу, 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. Пшихолопов	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», 2022
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

R. Yusupov, V. Osipov, A. Ronzhin SPIIRAS — 45 Years of Scientific Activity	1085
Artificial Intelligence, Knowledge and Data Engineering	
A. Dvoynikova, M. Markitantov, E. Ryumina, M. Uzdiaev, A. Velichko, D. Ryumin, E. Lyakso, A. Karpov ANALYSIS OF INFOWARE AND SOFTWARE FOR HUMAN AFFECTIVE STATES RECOGNITION	1097
V. Osipov, S. Kuleshov, D. Miloserdov, A. Zaytseva, A. Aksenov RECURRENT NEURAL NETWORKS WITH CONTINUOUS LEARNING IN PROBLEMS OF NEWS STREAMS MULTIFUNCTIONAL PROCESSING	1145
R. Zulkarneev, N. Yusupova, O. Smetanina, M. Gayanova, A. Vulfin METHOD AND MODELS OF EXTRACTION OF KNOWLEDGE FROM MEDICAL DOCUMENTS	1169
D. Zaitsev, V. Bryksin, K. Belotelov, Y. Kompaniets, R. Iakovlev ALGORITHMS AND MEASURING COMPLEX FOR CLASSIFICATION OF SEISMIC SIGNAL SOURCES, DETERMINATION OF DISTANCE AND AZIMUTH TO THE POINT OF EXCITATION OF SURFACE WAVES	1211
Digital Information Telecommunication Technologies	
G. Tsochev, K. Popova, I. Stankov A COMPARATIVE STUDY BY SIMULATION OF OSPF AND EIGRP ROUTING PROTOCOLS	1240
A. Obukhov, A. Volkov, A. Nazarova MICROSERVICE ARCHITECTURE OF VIRTUAL TRAINING COMPLEXES	1265
Information Security	
E. Basan, O. Peskova, O. Silin, A. Basan, E. Abramov DATA GENERATION FOR MODELING ATTACKS ON UAVS FOR THE PURPOSE OF TESTING INTRUSION DETECTION SYSTEMS	1290
I. Kotenko, I. Saenko, O. Lauta, A. Kriebel ANOMALY AND CYBER ATTACK DETECTION TECHNIQUE BASED ON THE INTEGRATION OF FRACTAL ANALYSIS AND MACHINE LEARNING METHODS	1328
Robotics, Automation and Control Systems	
D. Dudakova, V. Anokhin, M. Dudakov, A. Ronzhin ON THEORETICAL FOUNDATIONS OF AEROLIMNOLOGY: STUDY OF FRESH WATER BODIES AND COASTAL TERRITORIES USING AIR ROBOT EQUIPMENT	1359

СОДЕРЖАНИЕ

Р.М. Юсупов, В.Ю. Осипов, А.Л. Ронжин
СПИРАН — 45 ЛЕТ НАУЧНОЙ ДЕЯТЕЛЬНОСТИ 1085

Искусственный интеллект, инженерия данных и знаний
А.А. Двойникова, М.В. Маркитантов, Е.В. Рюмина, М.Ю. Уздяев,
А.Н. Величко, Д.А. Рюмин, Е.Е. Ляксо, А.А. Карпов
АНАЛИЗ ИНФОРМАЦИОННОГО И МАТЕМАТИЧЕСКОГО
ОБЕСПЕЧЕНИЯ ДЛЯ РАСПОЗНАВАНИЯ АФФЕКТИВНЫХ
СОСТОЯНИЙ ЧЕЛОВЕКА 1097

В.Ю. Осипов, С.В. Кулешов, Д.И. Милосердов, А.А. Зайцева, А.Ю. Аксенов
РЕКУРРЕНТНЫЕ НЕЙРОННЫЕ СЕТИ С НЕПРЕРЫВНЫМ ОБУЧЕНИЕМ
В ЗАДАЧАХ МНОГОФУНКЦИОНАЛЬНОЙ ОБРАБОТКИ НОВОСТНЫХ
ПОТОКОВ 1145

Р.Х. Зулкарнеев, Н.И. Юсупова, О.Н. Сметанина, М.М. Гаянова,
А.М. Вульфин
МЕТОДЫ И МОДЕЛИ ИЗВЛЕЧЕНИЯ ЗНАНИЙ ИЗ МЕДИЦИНСКИХ
ДОКУМЕНТОВ 1169

Д.Л. Зайцев, В.М. Брыксин, К.С. Белотелов, Ю.И. Компаниец, Р.Н. Яковлев
АЛГОРИТМЫ И ИЗМЕРИТЕЛЬНЫЙ КОМПЛЕКС КЛАССИФИКАЦИИ
ИСТОЧНИКОВ СЕЙСМИЧЕСКИХ СИГНАЛОВ, ОПРЕДЕЛЕНИЯ
РАССТОЯНИЯ И АЗИМУТА ДО ПУНКТА ВОЗБУЖДЕНИЯ
ПОВЕРХНОСТНЫХ ВОЛН 1211

Цифровые информационно-телекоммуникационные технологии
Г.Р. Цочев, К.К. Попова, И.С. Станков
СРАВНИТЕЛЬНОЕ ИССЛЕДОВАНИЕ МОДЕЛИРОВАНИЕМ
ПРОТОКОЛОВ МАРШРУТИЗАЦИИ OSPF И EIGRP 1240

А.Д. Обухов, А.А. Волков, А.О. Назарова
МИКРОСЕРВИСНАЯ АРХИТЕКТУРА ВИРТУАЛЬНЫХ ТРЕНАЖЕРНЫХ
КОМПЛЕКСОВ 1265

Информационная безопасность
Е.С. Басан, О.Ю. Пескова, О.И. Силин, А.С. Басан, Е.С. Абрамов
ГЕНЕРАЦИЯ ДАННЫХ ДЛЯ МОДЕЛИРОВАНИЯ АТАК НА БПЛА С
ЦЕЛЬЮ ТЕСТИРОВАНИЯ СИСТЕМ ОБНАРУЖЕНИЯ ВТОРЖЕНИЙ 1290

И.В. Котенко, И.Б. Саенко, О.С. Лаута, А.М. Крибель
МЕТОДИКА ОБНАРУЖЕНИЯ АНОМАЛИЙ И КИБЕРАТАК НА ОСНОВЕ
ИНТЕГРАЦИИ МЕТОДОВ ФРАКТАЛЬНОГО АНАЛИЗА И
МАШИННОГО ОБУЧЕНИЯ 1328

Робототехника, автоматизация и системы управления
Д.С. Дудакова, В.М. Анохин, М.О. Дудаков, А.Л. Ронжин
О ТЕОРЕТИЧЕСКИХ ОСНОВАХ АЭРОЛИМНОЛОГИИ: ИЗУЧЕНИЕ
ПРЕСНЫХ ВОДОЕМОВ И ПРИБРЕЖНЫХ ТЕРРИТОРИЙ С
ПРИМЕНЕНИЕМ ВОЗДУШНЫХ РОБОТОТЕХНИЧЕСКИХ СРЕДСТВ 1359

СПИИРАН — 45 ЛЕТ НАУЧНОЙ ДЕЯТЕЛЬНОСТИ

Федеральное государственное бюджетное учреждение науки Санкт-Петербургский институт информатики и автоматизации Российской академии наук (далее Институт) организован в соответствии с Распоряжением Совмина СССР от 19.12.1977 и постановлением Президиума АН СССР от 19.01.1978 на базе отдела вычислительной техники Физико-технического института им. А.Ф. Иоффе АН СССР как Ленинградский научно-исследовательский вычислительный центр АН СССР (ЛНИВЦ). В 1985 году ЛНИВЦ решением Президиума АН СССР преобразован в Ленинградский институт информатики и автоматизации АН СССР.

К 1991 году Институт вырос в крупное научно-исследовательское учреждение, на базе научных подразделений которого были организованы новые учреждения — Центр экологической безопасности Санкт-Петербургского Научного центра РАН (СПБНЦ РАН) и Межведомственный координационный совет СПБНЦ РАН. В 1992 году после возвращения городу Ленинграду исторического названия Санкт-Петербург Институт переименован в Санкт-Петербургский институт информатики и автоматизации РАН (СПИИРАН). Распоряжением Правительства Российской Федерации от 30 декабря 2013 г. № 2591-р Институт, как и другие учреждения РАН, передан в ведение Федерального агентства научных организаций (ФАНО России). Распоряжением Правительства Российской Федерации от 27 июня 2018 г. № 1293-р Институт передан в ведение Министерства науки и высшего образования Российской Федерации (Минобрнауки России).

Научное и научно-методическое руководство деятельностью СПИИРАН осуществляет РАН (Отделение нанотехнологий и информационных технологий РАН).

Основателем и первым директором Института стал доктор технических наук, профессор Пономарев Валентин Михайлович. С февраля 1991 г. по январь 2018 г. директором Института являлся член-корреспондент РАН, заслуженный деятель науки и техники Российской Федерации, доктор технических наук, профессор Юсупов Рафаэль Мидхатович. С января 2018 г. по июль 2020 г. директором Института являлся профессор РАН, доктор технических наук, профессор Ронжин Андрей Леонидович. С октября 2020 г. по настоящее время директором СПИИРАН является доктор технических наук, профессор Осипов Василий Юрьевич.

Тематика работ СПИИРАН с первых дней его существования практически соответствовала прорывным направлениям, сформулированным в последующем в руководящих документах: «Стратегия развития информационного общества в Российской Федерации на 2017–2030 годы», «Стратегия научно-технологического развития Российской Федерации», Государственная программа «Цифровая экономика Российской Федерации».

Целью и предметом деятельности СПИИРАН является проведение фундаментальных, поисковых и прикладных научных исследований, направленных на получение новых знаний в области информатики и информатизации, методов управления и информационно-коммуникационных технологий, системного анализа и робототехники для решения актуальных научно-технических и социально-экономических проблем. Проведение фундаментальных, поисковых и прикладных научных исследований на первом этапе существования Института осуществлялось по следующим основным направлениям: вычислительные комплексы коллективного пользования, компьютеризация и автоматизация научных исследований, проектирования, управления и производства. С начала 90-х годов в Институте начали проводиться исследования в области информатизации общества, интеллектуальных информационно-коммуникационных технологий для различных сфер деятельности, информационной безопасности, робототехники, биомедицинской информатики, цифровой экономики.

К 1983 году в Институте был создан самый мощный в стране на то время вычислительный комплекс, ресурсами которого пользовались около 2000 специалистов из 82 организаций в основном в режиме удаленного доступа. Параллельно была разработана и создана одна из первых в стране глобальных информационно-вычислительных сетей — Академсеть «Северо-Запад». Сеть объединяла терминалы удаленного доступа более 40 организаций Ленинграда и других городов (Москва, Петрозаводск, Таллин). Были разработаны связанные с сетью системы автоматизации научных исследований, что позволило создать на нескольких предприятиях Ленинграда интегрированные производственные комплексы, в которых автоматизируется весь жизненный цикл изделия «от разработки новой продукции до ее выпуска» (по сути — прообраз «промышленного интернета»).

С учетом научных достижений Института и накопленного опыта их практической реализации Институту было поручено научное сопровождение Целевой комплексной территориально-отраслевой программы развития народного хозяйства Ленинграда и Ленинградской области на основе автоматизации и широкого

использования вычислительной техники на 1984–1985 годы и до 1990 года «Интенсификация-90». В результате реализации программы по среднегодовым темпам роста производительность труда в промышленности увеличились в 1,5 раза по сравнению с предыдущей пятилеткой.

В девяностые годы прошлого века в развитии Института начался второй этап, который совпал с мировой тенденцией — процессом формирования информационного общества (общества знаний) как средства социально-экономического развития общества и обеспечения его национальной безопасности. Именно в эти годы под руководством директора Института Р.М. Юсупова были разработаны концептуальные основы информатизации, структурные и экономико-математические модели информационного общества, базирующиеся на наличии в информационном обществе двух секторов экономики: традиционного и информационного, основанного на знаниях. Результаты этих работ вывели Институт в ряд одного из ведущих отечественных научных учреждений в области информатизации общества и оказали ощутимое влияние на этот процесс не только в городе, но и в стране. Учеными Института разработаны научно-методологические основы информатизации общества. С их участием созданы концепция информатизации Санкт-Петербурга, стратегия его перехода к информационному обществу, концептуальные основы информационной политики, принятые Администрацией Санкт-Петербурга в качестве руководящих документов. Разработан ряд модельных законов для государств-участников Содружества Независимых Государств, в частности, об информатизации, о критически важных объектах инфокоммуникационной инфраструктуры, обеспечения информационной безопасности и так далее. Ряд подобных законов разработан также для государств — членов Организации Договора о коллективной безопасности.

Прикладные результаты исследований Института ориентированы на создание технологий, соответствующих Перечню критических технологий Российской Федерации. В числе разработок Института — широкий спектр современных информационных технологий:

- технология анализа и обработки больших данных (Big data) для решения задач обнаружения закономерностей, машинного обучения, построения моделей оценивания, прогнозирования и принятия решений на конечном множестве альтернатив;

- технология и программные средства анализа и агрегации больших массивов гетерогенных данных для мониторинга и

управления безопасностью распределенной сети электронных потребительских устройств (Интернет вещей);

- технология построения систем поддержки принятия решений на основе взаимодействия человеко-машинных облачных сервисов в онтолого-ориентированных интеллектуальных информационных пространствах;

- технология поддержки взаимодействия автономных робототехнических систем и пользователей в групповом поведении в окружающем киберфизическом пространстве;

- технология проектирования и производства бортовых вычислительных модулей для обработки сенсорной информации и управления активационными устройствами во встраиваемых системах и мобильных робототехнических комплексах;

- технология и компьютерная система паралингвистического анализа естественной речи для автоматического распознавания эмоциональных состояний человека по речи и классификации речевых паралингвистических явлений;

- методология импортозамещения компонентов аппаратного обеспечения их программными реализациями на основе развития концепции программно-определяемых систем;

- технология и программный комплекс решения математических задач прогнозного оценивания, анализа и синтеза характеристик систем и процессов их функционирования по показателям их операционных свойств;

- технология оценивания устойчивости работы информационной системы в условиях социоинженерных атакующих воздействий;

- технология построения многоуровневой геоинформационной интеллектуальной системы освещения наземной, надводной, подводной, воздушной и космической обстановки и поддержки принятия решений.

Перечисленные технологии готовы к реализации, ряд из них внедрен в научно-исследовательских и промышленных организациях и, что особенно важно, на практике решают задачи импортозамещения. Часть результатов имеет двойное назначение.

За прошедшие 45 лет Институт выполнил НИР и ОКР по следующим основным направлениям, связанным с оборонной тематикой и обеспечения национальной безопасности Российской Федерации: проблемы информационной безопасности и защиты информации в инфокоммуникационных комплексах и сетях; новые методы получения обработки и интеграции данных, информации и знаний; проблемы создания и применения межвидовых

интегрированных информационных интеллектуальных технологий и систем поддержки принятия решений. В результате осуществлено создание научно-методологического, методического и технического задела, необходимого для решения задач обеспечения технологической независимости российских разработчиков от зарубежных производителей в области проектирования, создания, эксплуатации и модернизации АСУ и специальной техники, качественного повышения уровня ее готовности, своевременности, обоснованности и гибкости формирования и реализации принимаемых решений и управляющих воздействий.

Основу научно-экспериментальной базы Института составляют центр коллективного пользования научным оборудованием «Северо-Западный центр мониторинга и прогнозирования развития территорий», Компьютерный научно-образовательный центр, Научно-образовательный центр «Технологии интеллектуального пространства», Инновационно-образовательный центр космических услуг, созданный по соглашению с Роскосмосом, Учебный центр для подготовки сертифицированных специалистов в области обработки данных дистанционного зондирования Земли.

Развивая интеграцию фундаментальной науки и высшего образования, ученые Института активно участвуют в реализации научно-образовательных программ в ведущих университетах Санкт-Петербурга, в том числе в рамках Программы «Приоритет 2030», а также поддержки исследовательских центров в сфере искусственного интеллекта. Институт имеет 6 базовых кафедр в вузах города и 9 совместных научно-исследовательских лабораторий в университетах города и России.

В соответствии с приказами Министерства науки и высшего образования Российской Федерации № 1399 от 18 декабря 2019 года и №768 от 08 июля 2020 года на базе Федерального государственного бюджетного учреждения науки Санкт-Петербургского института информатики и автоматизации Российской академии наук (СПИИРАН) с присоединением Федерального государственного бюджетного учреждения науки института озераведения Российской академии наук (ИНОЗ РАН); Федерального государственного бюджетного учреждения науки Санкт-Петербургского научно-исследовательского центра экологической безопасности Российской академии наук (НИЦЭБ РАН); Федерального государственного бюджетного научного учреждения «Северо-Западный научно-исследовательский институт экономики и организации сельского хозяйства» (ФГБНУ СЗНИЭСХ); Федерального государственного

бюджетного научного учреждения "Северо-Западный Центр междисциплинарных исследований проблем продовольственного обеспечения" (СЗЦППО); Федерального государственного бюджетного научного учреждения "Новгородский научно-исследовательский институт сельского хозяйства" (ФГБНУ «Новгородский НИИСХ») создано Федеральное государственное бюджетное учреждение науки «Санкт-Петербургский Федеральный исследовательский центр Российской академии наук» (СПБ ФИЦ РАН).

С июля 2020 г. директором СПБ ФИЦ РАН по настоящее время является профессор РАН, доктор технических наук, профессор Ронжин Андрей Леонидович.

Целью и предметом деятельности СПБ ФИЦ РАН являются выполнение фундаментальных, поисковых и прикладных научных исследований, направленных на получение новых знаний в сфере информатики и автоматизации, методов управления и информационных и коммуникационных технологий, экологической безопасности, природоохранной деятельности, продовольственной безопасности, экономики и организации агропромышленного комплекса, способствующих его технологическому, экономическому и социальному развитию, внедрение достижений науки и передового опыта, подготовка кадров высшей квалификации.

К основным научным направлениям Центра относятся:

- фундаментальные, технологические, правовые и социально-экономические основы построения информационного общества с цифровой экономикой, искусственного интеллекта, больших данных, информационной и кибербезопасности, постквантовых криптосистем, проактивного мониторинга и управления информационными процессами в сложных системах, создание интеллектуальных интегрированных систем поддержки принятия решений, технологий программно-определяемых систем, многомодальных пользовательских интерфейсов в человеко-машинных и робототехнических комплексах;

- эколого-экономические и правовые проблемы прогнозирования, диагностики и оперативного предупреждения угроз здоровью экосистем на различных жизненных циклах природно-хозяйственных объектов и реабилитации нарушенных, загрязненных техногенных ландшафтов и систем обращения с отходами;

- фундаментальные основы оценки и прогноза тенденций изменения природно-ресурсного потенциала озерного фонда России в различных физико-географических зонах с учетом природно-климатических и антропогенных факторов, его охрана и рациональное

геостратегическое использование с учетом социально-экономического развития регионов;

– фундаментальные основы рационального использования агроресурсного потенциала территорий, оптимизации и реконструкции мелиоративных систем, обеспечивающих сохранение природно-ресурсного потенциала и увеличения продуктивности агроландшафтов, сохранения и воспроизводства биологического разнообразия сельскохозяйственных животных и растений для обеспечения продовольственной и экологической безопасности РФ;

– фундаментальные и технологические основы управления производственным процессом агроэкосистем и возделывания экономически значимых сельскохозяйственных культур в целях создания высокопродуктивных агрофитоценозов на основе адаптации, средообразования, биологизации и производства сбалансированного высококачественного агросырья, удовлетворяющего потребности различных групп населения, в том числе в Арктической зоне РФ;

– фундаментальные основы инновационно-инвестиционного развития сельских территорий, земельных отношений и землепользования на основе интеграционных процессов в региональных агропромышленных комплексах.

В 2021 году при СПб ФИЦ РАН Центр коллективного пользования научным оборудованием «Северо-Западный центр мониторинга и прогнозирования развития территорий», являющийся единой платформой для совместной работы при выполнении междисциплинарных проектов на основе научно-методологического базиса – методов и технологий автоматизации мониторинга, комплексного моделирования природных и антропогенных объектов и процессов. С использованием платформы проведено визуальное комплексное моделирование и многокритериальное оценивание, адаптивное прогнозирование рисков аварий и катастроф в природно-технических системах; устойчивого и гармоничного использования биологических природных ресурсов в условиях интенсивного хозяйственного развития и климатических изменений; влияния изменений климата на безопасность населения, экосистем, сельское хозяйство; индивидуальных экономико-демографических и психологических характеристик общества, определяемых методами искусственного интеллекта.

Открытый при СПб ФИЦ РАН Международный центр цифровой криминалистики специализируется на коммерческих работах по сбору и анализу цифровых доказательств, судебной экспертизе в России и за рубежом, обучении основам цифровой криминалистики и научным исследованиям в области автоматизации

расследований. Подписанное соглашение о сотрудничестве с Санкт-Петербургской академией Следственного комитета Российской Федерации и другими высшими учебными заведениями открывает новые возможности в области кибербезопасности и права. Международный центр помогает представителям правоохранительных органов и юристам России и других стран раскрывать преступления, связанные с использованием цифровых технологий: похищение и повреждение данных, нарушение работоспособности программ и устройств, нелегальное использование интеллектуальной собственности.

При участии СПб ФИЦ РАН в 2020-2022 гг. были организованы 12 международных и российских конференций: Международная научно-практическая конференция «Имитационное и комплексное моделирование морской техники и морских транспортных систем» (ИКМ МТМТС) в рамках Международного Военно-морского Салона (МВМС), Всероссийская научно-практическая конференция по имитационному моделированию и его применению в науке и промышленности «Имитационное моделирование. Теория и практика» (ИММОД), конференция «Информационные технологии в управлении» (ИТУ) и конференция «Робототехника и мехатроника» (РиМ) в рамках российской мультikonференции по проблемам управления (МКПУ), Санкт-Петербургская международная конференция «Региональная информатика (РИ), Межрегиональная научно-практическая конференция «Перспективные направления развития отечественных информационных технологий», Санкт-Петербургская межрегиональная конференция «Информационная безопасность регионов России» (ИБРР), Всероссийская научно-практическая конференция «Перспективные системы и задачи управления», международная научная конференция «Технологическая перспектива в рамках евразийского пространства: новые рынки и точки экономического роста», всероссийская конференция «Современные тенденции развития химической технологии, промышленной экологии и экологической безопасности», всероссийская научная конференция с международным участием «Земля и космос» к столетию академика РАН К.Я. Кондратьева.

Труды 5 конференций индексируются в WoS/Scopus: международная конференция «Речь и Компьютер» (SPECOM) – топ-конференция А*, международная конференция по интерактивной коллаборативной робототехнике (ICR), международная конференция по параллельной, распределенной и сетевой обработке информации (PDP), международная конференция по электромеханике и

робототехнике «Завалишинские чтения» (ER(ZR)), международная конференция по цифровизации сельского хозяйства и органическому производству (ADOP).

С 2002 года СПб ФИЦ РАН является учредителем и издателем научного журнала «Информатика и автоматизация» (до 2020 года «Труды СПИИРАН»). С 2016 года журнал включен в международную базу цитирования Scopus, в Перечне ВАК имеет К1 и занимает в РИНЦ первое место в рейтинге SCIENCE INDEX по тематике "Автоматика. Вычислительная техника", "Кибернетика", «Математика» с 2018 года.

СПб ФИЦ РАН имеет право на осуществление образовательной деятельности по программам подготовки научно-педагогических кадров в аспирантуре согласно бессрочной лицензии № 2918 от 02.09.2020 Федеральной службы по надзору в сфере образования и науки и имеет государственную аккредитацию образовательной деятельности до 18 мая 2022 года. Прием осуществляется по следующим научным специальностям: 2.3.1. Системный анализ, управление и обработка информации, статистика; 2.3.5. Математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей; 2.3.6. Методы и системы защиты информации, информационная безопасность; 5.2.3. Региональная и отраслевая экономика. Функционирует докторский диссертационный совет по специальностям: 2.3.1, 2.3.5, 2.3.6.

В здании СПб ФИЦ РАН организована экспозиция научно-технической коллекции вычислительной техники СПИИРАН и функционирует Музей истории школы К. Мая, среди выпускников которой — выдающиеся ученые, художники, писатели, композиторы, государственные деятели: члены Госсовета, министры, губернаторы, космонавты Г.М. Гречко и А.И. Борисенко, генералы, адмиралы, в том числе 39 академиков Академии наук и Академии художеств. Используя потенциал коллекции и Музея, ученые СПб ФИЦ РАН ведут просветительскую и воспитательную работу со школьниками и студентами образовательных организаций Санкт-Петербурга и других городов, пропагандируя лучшие научные, педагогические и культурно-нравственные традиции российского образования и науки.

В Год науки и технологий в России молодые ученые СПб ФИЦ РАН Кашевник А.М. и Чечулин А.А. победители Президентской программы Российского научного фонда выступили с серией лекций в тематическом месяце «Обеспечение безопасности: новые вызовы и угрозы» в акции «На острие науки» и рассказали о своих разработках, позволяющих предотвратить пожары, обнаружить техногенные,

биогенные и террористические угрозы, защитить информационные системы и не дать утечь персональным данным.

Свыше 50 сотрудников СПб ФИЦ РАН в 2020-2022 гг. были отмечены ведомственными наградами, удостоены медалей и грамот Правительства Санкт-Петербурга, научных фондов и международных сообществ: Бакина Л.Г., Донченко В.К., Ронжин А.Л., Салухов В.И. – медаль «За вклад в реализацию государственной политики в области научно-технологического развития», Павлова О.А. – медаль «За безупречный труд и отличие» III степени, Зеленцов В.А., Никонова Г.Н. – почетное звание «Почетный работник науки и высоких технологий Российской Федерации», Тулупьева Т.В., Павлов А.Н. – почетное звание «Почетный работник сферы образования Российской Федерации», Сухорукова Н.Т. – почетная грамота Министерства науки и высшего образования Российской Федерации, Балун О.В., Зайцева А.А., Курашов Е.А., Чернова Е.Н., Чечулин А.А. – благодарность Министерства науки и высшего образования Российской Федерации за значительный вклад в развитие науки и многолетний добросовестный труд, Абрамов М.В., Егорова А.В., Савельев А.И. – нагрудный знак «Молодой ученый», Тесля Н.Н. – медаль Российской академии наук с премией для молодых ученых России по итогам конкурса 2020 года в области информатики, вычислительной техники и автоматизации, Микони С.В. – Премия "За заслуги в укреплении народного единства, сохранении культурного и исторического наследия" имени Александра Невского в номинации «Патриотизм».

В СПб ФИЦ РАН работают свыше 500 сотрудников, в том числе: 8 заслуженных деятелей науки Российской Федерации, 3 академика РАН, 3 члена-корреспондента РАН, 2 профессора РАН, 69 докторов наук и 126 кандидатов наук. Академик РАН, доктор биологических наук Василий Александрович Забродин – крупный ученый в области инфекционных и инвазионных болезней домашних оленей, диких промысловых животных и рыб Крайнего Севера; академик РАН, доктор географических наук Александр Иванович Костяев – видный ученый в области экономики и планирования агропромышленного комплекса, экономических и социальных проблем агропромышленного хозяйства Севера; академик РАН, доктор ветеринарных наук Касим Анверович Лайшев – крупный ученый в области ветеринарной инфектологии; член-корреспондент РАН, доктор экономических наук Галина Николаевна Никонова – выдающийся ученый в области управления агропромышленным комплексом; член-корреспондент РАН, доктор технических наук Рафаэль Мидхатович Юсупов – крупный ученый в области информатики, моделирования, теории управления (теория

адаптивных систем, идентификация, теория чувствительности), информатизации общества и информационной безопасности. Неоценим вклад член-корреспондента РАН, доктора экономических наук Александра Григорьевича Трафимова (1953-2020 гг.) в области экономики сельского хозяйства, работавшего в СПб ФИЦ РАН.

За свою историю Санкт-Петербургский институт информатики и автоматизации Российской академии наук закрепил за собой статус одного из ведущих научных центров Северо-Запада в области информатики и автоматизации и успешно продолжает исследования по созданию и внедрению стратегических цифровых технологий и роботизированных систем в интересах укрепления обороноспособности России, обеспечения безопасности и повышения качества жизни граждан.

СПб ФИЦ РАН перенимает опыт и наследие объединившихся научных организаций и успешно продолжает исследования по созданию и внедрению стратегических цифровых технологий и роботизированных систем в интересах повышения эффективности процессов управления социально-экономическим развитием Северо-Западного региона России, обеспечения безопасности и повышения качества жизни ее граждан.

В междисциплинарных исследованиях во главу угла ставятся цифровые технологии машинного обучения и искусственного интеллекта, обрабатывающие пространственно-временные данные в области экологии и сельского хозяйства, с целью формирования баз знаний, прогнозирования и формирования проактивных мер поддержки принятия решений.

Активно продолжаются работы над оборонными проектами, ведется диверсификация их результатов в гражданской сфере. Методы группового управления беспилотными летательными аппаратами успешно используются при мониторинге и обработке сельскохозяйственных культур открытого грунта. Встроенные беспроводные микроэлектронные устройства адаптированы для решения задач комплексной автоматизации сенсорных, силовых систем вертикальных ферм аэро-, гидропоники и установок замкнутого водоснабжения в сфере аквакультуры.

Информационно-аналитическая платформа поддержки принятия решений, реализованная в космической, авиационной, атомной отраслях, является основой для создания электронно-цифрового паспорта для сельскохозяйственной продукции растениеводства и животноводства. Методы машинного обучения и искусственные нейронные сети, используемые ранее для распознавания речи, текста,

видеоаналитики, сейчас применяются в исследованиях СПБ ФИЦ РАН для идентификации типов поведения стада крупно рогатого скота, аномалий зерна, сегментации подтопленных участков поля, фитопатологий микрозелени.

Системные междисциплинарные исследования становятся визитной карточкой СПБ ФИЦ РАН. Накопленные фундаментальные знания в области кибернетики, искусственного интеллекта, робототехники, безопасности, экологии, сельского хозяйства и инновационно-инвестиционного развития территорий применяются для создания прикладных решений по цифровой трансформации агроэкологического производства, укрепления продовольственной, экологической и информационной безопасности наших граждан.

Открывая новую стратегически важную пятилетку своей истории, СПБ ФИЦ РАН и СПИИРАН ставят перед собой амбициозные цели, достижение которых под силу только увлеченным, верным своему делу – науке, высококвалифицированным ученым.

Главный редактор журнала «Информатика и автоматизация», руководитель научного направления СПБ ФИЦ РАН, член-корреспондент РАН, заслуженный деятель науки и техники Российской Федерации, доктор технических наук, профессор Юсупов Р.М.

Директор СПИИРАН, доктор технических наук, профессор Осипов В.Ю.

Директор СПБ ФИЦ РАН, профессор РАН, доктор технических наук, профессор Ронжин А.Л.

А.А. ДВОЙНИКОВА, М.В. МАРКИТАНТОВ, Е.В. РЮМИНА, М.Ю. УЗДЯЕВ,
А.Н. ВЕЛИЧКО, Д.А. РЮМИН, Е.Е. ЛЯКСО, А.А. КАРПОВ
**АНАЛИЗ ИНФОРМАЦИОННОГО И МАТЕМАТИЧЕСКОГО
ОБЕСПЕЧЕНИЯ ДЛЯ РАСПОЗНАВАНИЯ АФФЕКТИВНЫХ
СОСТОЯНИЙ ЧЕЛОВЕКА**

Двойникова А.А., Маркинтантов М.В., Рюмина Е.В., Уздяев М.Ю., Величко А.Н., Рюмин Д.А., Ляксо Е.Е., Карпов А.А. Анализ информационного и математического обеспечения для распознавания аффективных состояний человека.

Аннотация. В статье представлен аналитический обзор исследований в области аффективных вычислений. Это направление является составляющей искусственного интеллекта, и изучает методы, алгоритмы и системы для анализа аффективных состояний человека при его взаимодействии с другими людьми, компьютерными системами или роботами. В области интеллектуального анализа данных под аффектом подразумевается проявление психологических реакций на возбуждаемое событие, которое может протекать как в краткосрочном, так и в долгосрочном периоде, а также иметь различную интенсивность переживаний. Аффекты в рассматриваемой области разделены на 4 вида: аффективные эмоции, базовые эмоции, настроение и аффективные расстройства. Проявление аффективных состояний отражается в вербальных данных и невербальных характеристиках поведения: акустических и лингвистических характеристиках речи, мимике, жестах и позах человека. В обзоре приводится сравнительный анализ существующего информационного обеспечения для автоматического распознавания аффективных состояний человека на примере эмоций, сентимента, агрессии и депрессии. Немногочисленные русскоязычные аффективные базы данных пока существенно уступают по объему и качеству электронным ресурсам на других мировых языках, что обуславливает необходимость рассмотрения широкого спектра дополнительных подходов, методов и алгоритмов, применяемых в условиях ограниченного объема обучающих и тестовых данных, и ставит задачу разработки новых подходов к аугментации данных, переносу обучения моделей и адаптации иноязычных ресурсов. В статье приводится описание методов анализа одномодальной визуальной, акустической и лингвистической информации, а также многомодальных подходов к распознаванию аффективных состояний. Многомодальный подход к автоматическому анализу аффективных состояний позволяет повысить точность распознавания рассматриваемых явлений относительно одномодальных решений. В обзоре отмечена тенденция современных исследований, заключающаяся в том, что нейросетевые методы постепенно вытесняют классические детерминированные методы благодаря лучшему качеству распознавания состояний и оперативной обработке большого объема данных. В статье рассматриваются методы анализа аффективных состояний. Преимуществом использования многозадачных иерархических подходов является возможность извлекать новые типы знаний, в том числе о влиянии, корреляции и взаимодействии нескольких аффективных состояний друг на друга, что потенциально влечет к улучшению качества распознавания. Приводятся потенциальные требования к разрабатываемым системам анализа аффективных состояний и основные направления дальнейших исследований.

Ключевые слова: аффективные состояния, аффективные вычисления, эмоции, сентимент, депрессия, агрессия, корпуса данных, компьютерные системы.

1. Введение. На протяжении последнего десятилетия активно развивается направление аффективных вычислений в области искусственного интеллекта. Аффективные вычисления (англ. Affective Computing) – область искусственного интеллекта, изучающая методы, алгоритмы, системы и устройства для анализа человеческих аффектов при его взаимодействии с другим человеком или машиной (роботом) [1]. Аффективные состояния играют значительную роль в человеческой жизни. С помощью них человек осуществляет субъективную оценку явлений, событий и ситуаций; побуждается к действиям; адаптируется к ситуациям; выражает свое внутреннее состояние; осуществляет регуляцию поведения [2]. Первое определение аффекта было опубликовано в 1897 немецким психологом Крафт-Эбингом. Он считал, что аффект – это сильное душевное волнение [3]. В современной психологии термины «аффект» и «эмоции» являются связными понятиями. Считается, что аффект – сильно выраженное эмоциональное проявление, и как разновидность эмоции характеризуется быстрым возникновением, высокой интенсивностью, кратковременностью, безотчетностью [4]. В то же время некоторые психологи [5] разделяют понятия аффектов и эмоций, подразумевая под аффектами неуправляемые переживания, когда проявление эмоций – самоуправляемое состояние человека.

Определение аффекта в области аффективных вычислений несколько отличается от его дефиниций в психологии и криминалистике. В существующих исследованиях нет четкого определения аффекта, поэтому существует необходимость раскрыть термин «аффект» в области аффективных вычислений. Под аффектом подразумевается проявление психологических реакций на возбуждаемое событие, которое может протекать как в краткосрочном, так и в долгосрочном периоде, а также иметь различную интенсивность переживаний. Можно выделить несколько видов аффекта, которые обобщенно представлены на рисунке 1.

Аффекты в области интеллектуального анализа данных делятся на 4 вида: аффективные эмоции, базовые эмоции, настроение и аффективные расстройства. Аффективные эмоции (например, агрессия) характеризуются высокой интенсивностью проявлений, являются незамедлительной и неконтролируемой реакцией на события, а также имеют небольшую длительность проявлений. Агрессия – целенаправленное наступательное поведение, которое наносит вред одушевленным и неодушевленным объектам нападения [6]. Базовые эмоции (радость, грусть, удивление и др.), в отличие от аффективных, имеют более низкую интенсивность и высокую

продолжительность переживаний [7]. Настроение представляет собой эмоциональное состояние, которое может продолжаться длительный период. Автоматический анализ настроений можно наблюдать в задачах сентимент-анализа [8] и распознавания токсичности. Сентимент – субъективное выражение мнений, взглядов, отношений к ситуациям или предметам. Иногда под сентиментом подразумевают определение полярности эмоции (позитив и негатив) [7]. Под токсичностью подразумевается поведение человека, которое вносит деструктив с отрицательной полярностью в нормы общения между людьми. Как правило, токсичность проявляется в текстовой модальности, поэтому задача распознавания токсичности в комментариях социальных сетей на сегодняшний день является актуальной (<https://www.kaggle.com/competitions/jigsaw-toxic-comment-classification-challenge> – 2018). Аффективные расстройства выражаются в психологических нарушениях, которые характеризуются несознательной сменой настроения, преимущественно в сторону отрицательной полярности, которое может выражаться в угрозах, нецензурной лексике, оскорблениях и пр. Как правило, аффективные расстройства, например депрессия, могут протекать от недель до нескольких лет [9]. Депрессия является нарушением психического здоровья человека, оказывающая негативное влияние на его мысли и поступки [10]. Различные аффективные состояния могут иметь корреляционную зависимость между собой.

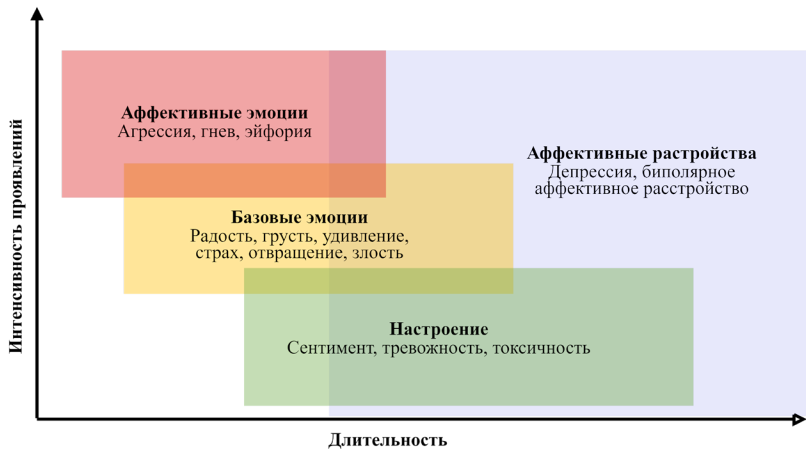


Рис. 1. Систематизация видов аффекта в области аффективных вычислений

Автоматическое определение аффективных состояний человека является актуальной и востребованной задачей в области искусственного интеллекта. Автоматические системы анализа и непрерывного мониторинга состояния человека позволяют оценивать и интерпретировать проявленные эмоции, настроения, тем самым, предоставляя возможность своевременно реагировать на изменение психоэмоциональных характеристик пользователей и адаптировать стратегию взаимодействия. В частности, использование автоматизированных экспертных систем мониторинга, распознавания и анализа состояний депрессии значительно облегчит работу врачей-специалистов и позволит получить дополнительные данные, которые могут быть недоступны из-за отсутствия постоянного контакта между пациентом и специалистом. Распознавание агрессии имеет большое значение для регуляции социальных взаимодействий не только во время живого общения, но и в виртуальном интернет-пространстве. С помощью анализа текстовой модальности можно распознавать проявления кибербуллинга и токсичности. Это особенно важно в условиях дистанционного образования, общения в социальных сетях, просмотре новостей и т.д.

Проявление аффективных состояний человека выражаются в его акустических и лингвистических характеристиках речи, а также мимики, позах, жестах, и физиологических сигналах (пульс, давление, электропроводность, цвет кожи и т.д.). При автоматическом определении аффективных состояний важно учитывать как вербальные, так и невербальные характеристики, на которые обращают внимание специалисты при личной беседе с людьми. К вербальным относятся ключевые слова, фразы и выражения, отражающие мысли говорящего, к невербальным признакам – просодические характеристики голоса (тон, тембр, громкость, интонация), мимика, направление взгляда, жесты и т.д. Для анализа физиологических сигналов используют контактные сенсоры, такие как пульсометры, электроды и пр. При наличии отвлекающих факторов (приборы на теле) у человека проявление аффективных состояний будет изменено, тем самым, анализ естественных внутренних переживаний человека становится невозможным. Поэтому репрезентативными модальностями для построения автоматической системы анализа аффективных состояний являются видео, аудио и текстовая информация. Анализ нескольких каналов информации (многомодальный подход) имеет преимущества перед одномодальным анализом [11], в том числе более высокую точность и устойчивость к

пропущенным данным, например, в случае технического сбоя или чрезмерного шума в одной из модальностей.

Целью статьи является сравнительный аналитический обзор существующих методов распознавания различных аффективных состояний человека – эмоций, сентимента, агрессии, депрессии. Для достижения цели необходимо выполнить основную задачу, которая заключается в сравнительном анализе корпусов данных, содержащих рассматриваемые аффекты. Предложенный аналитический обзор помогает выявить наиболее репрезентативное информационное обеспечение, выделить достоинства и недостатки применяемых методов для распознавания аффективных состояний, обнаружить нерешенные проблемы в рассматриваемой области, а также определить требования к разрабатываемым системам для анализа аффектов. Существует большое количество зарубежных работ на тему анализа аффективных состояний человека, однако в России количество таких исследований крайне мало. Поэтому предложенный аналитический обзор является актуальным.

2. Анализ информационного обеспечения. В мире накоплен большой объем данных (информационного обеспечения) для анализа аффективных состояний. В данной статье рассматриваются только многомодальные корпуса, ниже приводится их описание, сгруппированное по аффективным состояниям, прилагаются также сравнительные таблицы с основными характеристиками корпусов.

2.1. Эмоции. Аудиовизуальный корпус Acted Facial Expressions in the Wild (AFEW) [12] (<https://cs.anu.edu.au/few/AFEW.html>) содержит короткие эмоциональные записи из различных художественных фильмов (возраст актеров – 1-70 лет). Корпус аннотирован на уровне фраз. Часть записей из корпуса AFEW и собранные новые записи аннотированы на уровне кадров на пространственные оценки валентности и интенсивности и 68 координат ключевых точек лица, что позволило собрать еще один независимый корпус AFEW-VA [13] (<https://ibug.doc.ic.ac.uk/resources/afew-va-database/>) (возраст актеров – 8-76 лет, 52% – женщины.). Количественные оценки валентности и интенсивности измеряются в диапазоне [-10; 10]. Все данные корпуса AFEW-VA размечали 2 эксперта.

Аудиовизуальный корпус Aff-Wild2 [14] (<https://ibug.doc.ic.ac.uk/resources/aff-wild2/>) содержит записи (39% дикторов – женщины) YouTube. Тематика записей корпуса различная. Разметка корпуса выполнялась 4 экспертами на уровне кадра по эмоциям и единицам действия лица (Action Units) [15].

Многомодальный корпус Interactive Emotional
Dyadic Motion Capture (IEMOCAP) [16]
(https://sail.usc.edu/iemocap/iemocap_release.htm) собран посредством диадического взаимодействия двух актеров (5 пар актеров, 50% – женщины). Для захвата движений мышц лица, головы и рук при различных эмоциях на теле актеров наносились 59 маркеров. Каждая запись аннотирована не менее 3 экспертами на уровне высказываний, а также самооценкой.

Многомодальный корпус RECOLA [17]
(<https://diuf.unifr.ch/main/diva/recola/download.html>) записывался посредством взаимодействия двух участников (23 группы, 59% участников – женщины) с использованием оборудования для анализа электрокардиограмм (ЭКГ) и электродермальной активности. Записи корпуса размечались 6 экспертами на уровне кадров.

Многомодальный корпус SEWA [18] (<https://db.sewaproject.eu/>) записывался в натуральных условиях в результате двух экспериментов над участниками (возраст – 18-60 лет, 49% – женщины). В рамках первого эксперимента пара участников просматривала 4 рекламных ролика по 60 с, во время второго – эти же участники обсуждали их. Каждый участник по завершении экспериментов заполнял отчет о своем эмоциональном состоянии. Корпус аннотирован на ключевые точки лица, единицы действия лица, низкоуровневые дескрипторы речи, а также пространственные оценки валентности, интенсивности, симпатии/антипатии, согласия/несогласия и наличия случаев непредвиденных ситуаций, разметка выполнена 5 экспертами. Участники общались между собой на 6 различных языках: китайский, английский, немецкий, греческий, венгерский, сербский.

Аудиовизуальный корпус SEMAINE [19] (<https://semaine-db.eu/>) записывался при взаимодействии пользователей (возраст 22-60 лет, 62% – женщины) с 4 аватарами. Для записи использовались 5 видеокамер и 4 микрофона.

Аудиовизуальный корпус RAMAS [20] записан в результате взаимодействия двух актеров (5 пар, 50% – женщины, возрастной диапазон 18-20 лет). Корпус размечен 21 экспертом на уровне временных сегментов записи. В том числе актеры также предоставили самооценки их эмоций по шкале Лайкерта (англ. Likert scale) (от 0 – «нет признаков эмоции» до 3 – «сильно выражена эмоция»).

Многомодальный корпус Multimodal EmotionLines Dataset (MELD) [21] (<https://affective-meld.github.io/>) содержит короткие эмоциональные высказывания из телесериала «Друзья». Корпус размечен 3 экспертами отдельно на основе текстовой и

аудиовизуальной информации на уровне высказываний. Итоговая метка для данных выбиралась посредством мажоритарного голосования.

Многомодальный корпус CMU Multimodal Opinion Sentiment and Emotion Intensity (CMU-MOSEI) [22] (<https://github.com/A2Zadeh/CMU-MultimodalSDK>) содержит видеоролики из YouTube. Тематика записей корпуса различна, всего рассмотрено 250 тем (обзоры, дебаты, консультации и др.). Деление на записи выполнялось с учетом начала и конца предложения. На одного диктора (43% дикторов – женщины) приходится не менее 10, и не более 50 высказываний. Каждое предложение аннотировано на 7 классов сентимента и 6 базовых категорий эмоций по шкале Лайкерта.

2.2. Сентимент. Для задачи распознавания сентимента известны 4 многомодальных корпуса данных. Корпус Multimodal Opinion Utterances Dataset (MOUD) [23] (<http://multicomp.cs.cmu.edu/resources/moud-dataset/>) содержит видеоролики с YouTube на различные темы. Поскольку дикторы (возраст – 20-60 лет, 81% – женщины) могли разговаривать на разные темы в одном видео, авторы корпуса выбирали 30 секундный фрагмент из каждого видео. Каждый видеофрагмент разделен на высказывания (в общей сложности 498). Разметка проводилась 2 экспертами на уровне высказываний.

Многомодальный корпус Multimodal Opinion-Level Sentiment Intensity (MOSI) [24] (<http://multicomp.cs.cmu.edu/resources/cmu-mosi-dataset/>) представляет собой набор видеороликов из YouTube на различные темы (возраст участников – 20-30 лет, 46% – женщины). Из всех видео выбраны высказывания (в общей сложности 2199), в которых присутствовала субъективность, выражающаяся во мнении или отношении человека к чему-либо. Корпус размечен 5 экспертами на уровне высказываний по сентименту, а также по мимике, движениям лица и головы.

Авторы базы данных YOUTUBE Dataset [25] (<http://multicomp.cs.cmu.edu/resources/youtube-dataset-2/>) отбирали видео (возраст участников 14-60 лет, 42% – женщины) по следующим ключевым словам: мнение, обзор, лучшие духи, я ненавижу, мне нравится и др. Авторы корпуса сокращали каждое видео до 30 с, затем полученные фрагменты размечались тремя экспертами.

Китайский многомодальный корпус CH-SIMS Dataset [26] (<https://github.com/thuiar/MMSA>) содержит данные (34% дикторов – женщины) из различных фильмов, сериалов, телешоу. Авторы корпуса разделили каждое видео на фрагменты длиной от 1 до 10 с, в каждом

фрагменте присутствует только один диктор. Разметка корпуса производилась 5 экспертами на уровне одной записи.

Текстовая модальность является наиболее репрезентативной для определения сентимента. Известны несколько русскоязычных лингвистических корпусов [8]: RuTweetCorp, РОМИП 2012, RuSentiment, LinisCrowd, SentiRuEval, Auto_reviews и др.

Поскольку эмоции и сентимент являются родственными понятиями в области искусственного интеллекта, в таблицах 1 и 2 представлены сравнительные характеристики корпусов для распознавания эмоций и сентимента. В таблицах приводится параметр – тип речи (подготовленная или спонтанная), обозначающий вариативность лексического содержания высказываний. Во всех корпусах, где присутствует текстовая модальность данных, авторы извлекли орфографические транскрипции вручную.

Таблица 1. Характеристики многомодальных корпусов для анализа эмоций

Название корпуса	Модальности				Объем корпуса		Разметка	Количество дикторов	Условия записи	Тип речи	Язык речевых данных
	В	А	Т	Ф	Часов	Записей					
AFEW [12]	+	+	-	-	2,5	1645	7 эмоций	330	Нат	П	Английский
AFEW-VA [13]	+	+	-	-	н/д	600	валентность, интенсивность	240	Нат	П	Английский
AffWild2 [14]	+	+	-	-	43	558	7 эмоций, валентность, интенсивность	458	Нат	С	Английский
IEMOCAP [16]	+	+	+	-	11,5	1003 9	5 эмоций, валентность, активация, доминирование	10	Лаб	П и С	Английский
RECOLA [17]	+	+	-	+	4	46	валентность, интенсивность; доминирование; согласие, вовлеченность, исполнительность, взаимопонимание.	46	Лаб	С	Французский

Продолжение Таблицы 1

SEWA [18]	+	+	+	-	44	1990	валентность, интенсивность	398	Нап	С	6 языков
SEMAINE [19]	+	+	-	-	6,5	80	7 эмоций, валентность, активация; влияние; предвкушение; эпистемологические состояния, процесс взаимодействия, достоверность.	20	Лаб	С	Английский
RAMAS [20]	+	+	-	+	7	581	7 эмоций, доминирование, подчинение	10	Лаб	С	Русский

Таблица 2. Характеристики многомодальных корпусов для анализа эмоций и сентимента

Название корпуса	Модальности			Объем корпуса		Разметка	Количество дикторов	Язык речевых данных
	В	А	Т	Часов	Записей			
MELD [21]	+	+	+	н/д	13708	7 эмоций, 3 сентимента	6	Английский
CMU-MOSEI [22]	+	+	+	66	23453	7 эмоций, 7 сентиментов	1000	Английский
MOUD [23]	+	+	+	0,6	80	3 сентимента	80	Испанский
MOSI [24]	+	+	+	н/д	93	7 сентиментов	81	Английский
YOUTUBE [25]	+	+	+	0,3	47	3 сентимента	47	Английский
CH-SIMS [26]	+	+	+	н/д	2281	5 сентиментов	2281	Китайский

В таблице 2 все условия записи данных корпуса являются натурными, тип речи – спонтанный. Как правило, анализируется такой набор из 5-7 базовых эмоций: злость, отвращение, страх, печаль, радость, удивление и нейтральное состояние. При упоминании в таблице трех классов сентимента подразумевают позитивный, нейтральный, негативный и также могут добавляться их градации.

В таблицах 1, 2, 3 и 4 используются следующие сокращения: В – видео, А – аудио, Т – текст, Ф – физиологические сигналы, Нат – натурные, Лаб – лабораторные, П – подготовленная, С – спонтанная, н/д – нет данных.

Из таблицы 1 и 2 следует, что существует большое количество многомодальных корпусов для распознавания эмоций. Наборов данных для распознавания сентимента в различных модальностях значительно меньше, это может быть связано с тем, что большинство людей выражает свое мнение только с помощью текстовых сообщений. Также большинство корпусов имеет натурные условия записи (англ. in-the-wild) и спонтанную речь, что является значительным преимуществом для автоматической системы анализа аффективных состояний.

Помимо многомодальных корпусов для распознавания агрессии существует небольшое число одномодальных визуальных корпусов, в которых содержатся записи уличных драк с камер наблюдения [31–33], а также текстовых, представленных в работах [34, 35]. В таблице 3 представлены сравнительные характеристики многомодальных корпусов для распознавания агрессии. Во всех рассмотренных данных тип речи – спонтанный. Авторы всех рассмотренных корпусов извлекли текстовые транскрипции ручным методом. Запись корпусов TR и SD проводилась в натуральных условиях, а NAA – в лабораторных.

Таблица 3. Характеристики многомодальных корпусов для анализа агрессии

Название корпуса	Модальности				Объем корпуса		Разметка	Количество дикторов	Язык речевых данных
	В	А	Т	Ф	Часов	Записей			
TR [27]	+	+	+	-	0,6	н/д	3 уровня агрессии	н/д	Нидерландский
SD [28, 29]	+	+	+	-	0,5	8	3 уровня агрессии 5 уровней стресса	9	Английский, нидерландский
NAA [30]	+	+	+	+	н/д	2240	5 уровней агрессии, страха, интенсивности 9 уровней валентности	16	Нидерландский

Анализ использованных методик записи корпусов показывает слабую проработку критериев определения агрессивного поведения при разметке: для оценки агрессивного поведения часто агрессия путается с гневом, демонстративным поведением и т.д. Все рассмотренные корпуса, содержащие многомодальные проявления агрессии, находятся в закрытом доступе. Кроме этого, данные корпуса имеют малые размеры и малую репрезентативность с точки зрения количества представленных людей. Ввиду этого остро стоит необходимость сбора и разметки нового корпуса многомодальных данных, содержащих агрессивное поведение.

В дальнейшем авторами данной статьи планируется собрать корпус данных, содержащий агрессивное поведение пользователей информационного пространства в различных модальностях: двигательная активность и мимические изменения, представленные на видео, невербальное речевое поведение, представленное в аудиосигнале, вербальное речевое поведение в текстовых транскрипциях. Другими отличительными особенностями данного корпуса являются большая по сравнению с известными корпусами репрезентативность испытуемых, отбор поведения русскоязычных пользователей, а также относительная естественность поведения, которая обеспечивается тем, что в данный корпус планируется отбор поведения пользователей в ходе прямых трансляций в сети Интернет, что полностью исключает вмешательство внешнего наблюдателя в поведение испытуемых.

2.3. Депрессия. Корпус Distress Analysis Interview Corpus (DAIC) [36] содержит записи клинических интервью, а целью его разработки было определение наличия риска посттравматического стрессового расстройства (ПТСР) и большого депрессивного расстройства (БДР). В корпусе содержатся несколько типов интервью: очные, телеконференции, интервью в режиме «Волшебник страны Оз» (с использованием анимированного виртуального интервьюера Элли, которая управлялась интервьюером в другой комнате), автоматические интервью (с использованием Элли в автоматическом режиме без управления интервьюером в другой комнате).

В работе [37] представлен многомодальный корпус Audio-Visual Depressive language corpus (AViD-Corpus), который включает в себя записи взаимодействия людей с компьютером. Информантам были даны следующие задания: чтение новелл и преданий, пение и др. Корпус был аннотирован на уровне записей согласно шкале Бека-2 (это второй пересмотр опросника Бека, который был принят в 1996 году). Опросник состоит из 21 вопроса, а каждый вопрос оценивается

по шкале от 0 до 3 в зависимости от тяжести симптомов. Общий балл составляет от 0 до 63, где чем выше значение, тем серьезнее симптомы депрессии.

Корпус Pitt [38] был собран на основе клинического интервью с использованием шкалы Гамильтона (англ. The Hamilton Depression Rating Scale, HRSD) и опросника симптомов депрессии (англ. The 16-item Quick Inventory of Depressive Symptomatology and Self-Report, QIDS-SR). Шкала депрессии Гамильтона является одним из наиболее часто используемых инструментов для выявления симптомов депрессии, а также считается стандартом оценки эффективности медикаментозного лечения депрессивных расстройств. Заполняется специалистом при проведении клинического интервью, общий балл составляет от 0 до 21, где чем выше значение, тем серьезнее симптомы депрессии. QIDS-SR состоит из 16 вопросов для самооценки депрессивных симптомов, имеет также вариации для специалистов (QIDS-C), является упрощенной версией опросника Inventory of Depressive Symptoms (IDS), состоящего из 30 вопросов. Суммарный балл составляет от 0 до 27.

Многомодальный корпус BlackDog [39] содержит записи интервью, которые состояли из вопросов с открытым ответом. Бинарные метки классификации («здоровые субъекты» и «тяжелая депрессия») были проставлены вручную.

Корпус Sonde Health Free Speech (SH2-FS) содержит записи информантов в естественных условиях (в машине, дома, на работе), представлен в работе [40]. Аннотация сделана с использованием данных самодиагностического теста PHQ-9. Данный тест также является одним из часто используемых для самооценки симптомов депрессии, состоит из 9 вопросов. Суммарный балл составляет от 0 до 27.

Для распознавания депрессии существуют также одномодальные корпуса [9]: аудиокорпус Mundt, русскоязычный текстовый корпуса RusNeuroPsych, корпус эссе, а также корпус информации из профилей социальной сети «ВКонтакте» (изображения, собранные из альбомов, аватаров, постов в профилях). В таблице 4 представлена сравнительная характеристика многомодальных корпусов для распознавания депрессии. Запись всех рассмотренных корпусов проводилась в натуральных условиях. В корпусе DAIC транскрипции извлечены автоматическим способом, а в корпусе Pitt – ручным. Во всех корпусах язык речевых данных – английский.

Во многих случаях исследователи сталкиваются с проблемой нехватки данных из-за того, что речевых корпусов, содержащих

проявления депрессии, относительно мало, что естественно ввиду множества факторов. Например, область паралингвистики является относительно новой, хотя к ней проявляется повышенный интерес среди ученых. Кроме того, процесс сбора таких специфичных данных является трудоемким и времязатратным, а также не всегда возможно провести запись в естественных условиях, что непосредственно сказывается на количестве существующих речевых корпусов, их объемах и длительности аудиозаписей.

Существующие корпуса для задач аффективных вычислений являются ограниченными по размеру и количеству доступных данных. Русскоязычные корпуса значительно уступают базам данных на других мировых языках, таких как английский, немецкий или китайский, что обуславливает необходимость в рассмотрении широкого спектра дополнительных методов и алгоритмов решения задачи автоматического распознавания в условиях ограниченного объема доступных данных и в том числе в разработке новых подходов к аугментации данных, переносу обучения и адаптации иноязычных ресурсов.

Таблица 4. Характеристики многомодальных корпусов для анализа депрессии

Название корпуса	Модальности			Объем корпуса, часов	Разметка	Количество участников	Тип речи
	В	А	Т				
DAIC [36]	+	+	+	73,2	5 опросников	н/д	С
Pitt [38]	+	+	+	5,9	5 уровней депрессии	19	П
AViD-Corpus [37]	+	+	-	240	4 уровня депрессии	292	П и С
SH2-FS [40]	+	+	-	16	5 уровней депрессии	887	С
BlackDog [39]	+	+	-	8,5	5 уровней депрессии	30	С

3. Анализ методов автоматического распознавания аффективных состояний. Общая схема базовой системы автоматического распознавания аффективных состояний [7] представлена на рисунке 2.

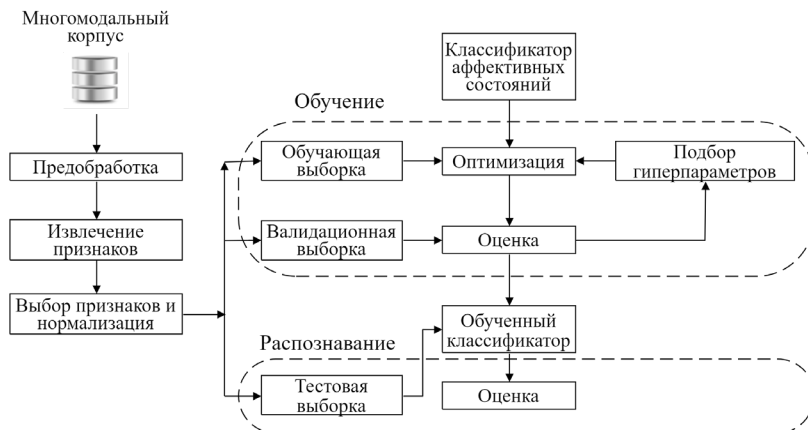


Рис. 2. Общая схема базовой системы автоматического распознавания аффективных состояний

Важными этапами в данной схеме являются извлечение информативных признаков, их выбор и нормализация, а также выбранный метод классификации. Различные методы, которые используются на данных этапах, будут рассмотрены ниже. Наиболее информативными модальностями для анализа аффективных состояний являются видео, аудио и текстовые данные. На рисунке 3 показаны основные современные методы извлечения признаков и классификации данных по каждой из модальностей; синим, желтым и фиолетовым цветами отмечена информация, относящаяся к видео, аудио и текстовой модальностям, соответственно, зеленым выделена информация, имеющая отношение ко всем модальностям одновременно.

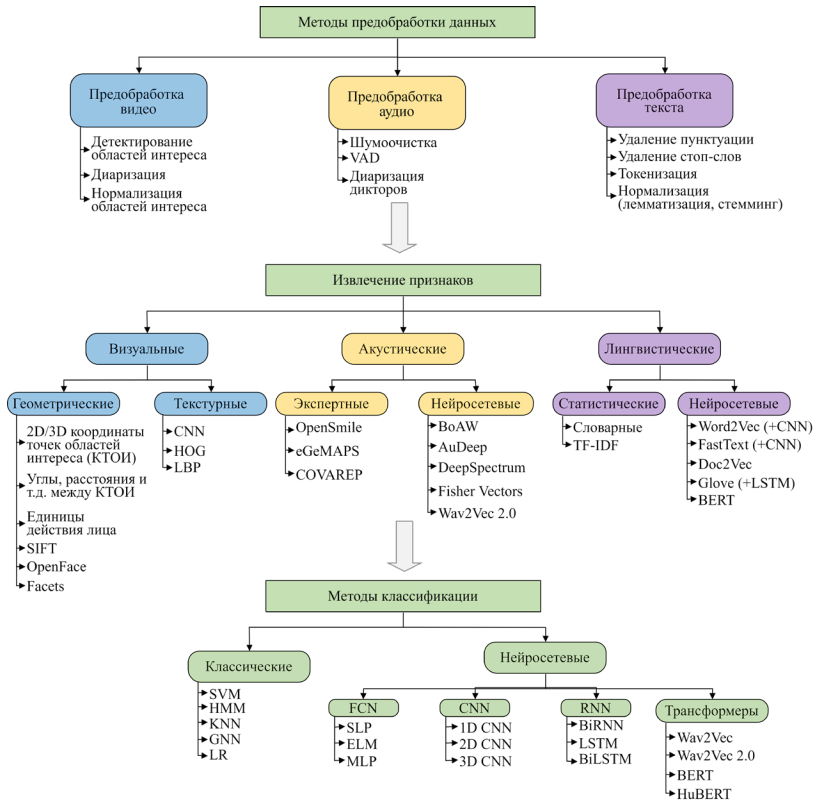


Рис. 3. Классификация методов извлечения признаков и классификации для видео, аудио и текстовой модальностей

Для каждой модальности ниже представлены описание основных методов извлечения признаков и классификации.

3.1. Видеомодальность. Классификация методов представления визуальных признаков. В данном разделе рассмотрены наиболее популярные подходы к извлечению визуальных признаков. Условно все признаки можно разделить на две группы: геометрические и текстурные признаки.

К геометрическим признакам относятся, например, 2D/3D координаты точек областей интереса, которые можно извлечь с помощью программных библиотек с открытым исходным кодом: OpenPose (<https://cmu-perceptual-computing-lab.github.io/openpose/web/html/doc/index.html>) – детектирование 3D 135 координат ключевых точек тела, лица, рук и ног; MediaPipe

(<https://google.github.io/mediapipe/>) – детектирование 3D 33 координат ключевых точек тела, 21 – точек рук, 468 – точек лица; Dlib (<http://dlib.net/>) – детектирование 68 ключевых точек лица и др. На основе 2D/3D координаты точек областей интереса извлекаются признаки: расстояния и углы между координатами [41]; площади областей интереса [42]; единицы действия лица (action units [15]); пространственные изменения координат точек областей интереса, вычисляемые с помощью подхода Scale-Invariant Feature Transform (SIFT) [18], и др. Известны библиотеки с открытым исходным кодом, например, OpenFace (<https://github.com/TadasBaltrusaitis/OpenFace>) и Facets (<https://imotions.com/blog/facial-expression-analysis/>), извлекающие на основе геометрии лица готовые наборы признаков, включающие 2D/3D координаты точек лица, единицы действия лица и др.

Текстурные признаки извлекаются, например, с помощью сверточных нейронных сетей (англ. Convolutional Neural Network, CNN). К наиболее эффективным CNN для задачи распознавания аффективных состояний относятся архитектуры нейросетей ResNet [43] и VGG [44]. Также для извлечения текстурных признаков можно выделить подход Local Binary Patterns (LBP) [45]. При таком подходе значения каждого центрального пикселя и 8 значений пикселей в его окрестности преобразуются из значений в диапазоне от 0 до 255 в бинарные, что позволяет выделить на изображении лица углы и края, характерные для определенной мимики. Еще одним подходом для извлечения текстурных признаков является Histogram of Oriented Gradients (HOG) [46]. При таком подходе признаками являются значения градиентов (производных по x и y), которые увеличиваются по краям и углам (в областях резкого изменения интенсивности пикселей).

Для извлечения геометрических признаков требуется более надежные подходы обнаружения, так как они более чувствительны к шуму (повороту головы, окклюзия лица и т.д.). В то время как текстурные признаки трудно обобщить под всех людей, поскольку они зависимы от освещения и цвета кожи.

3.2. Аудиомодальность. Классификация методов представления акустических признаков. Акустические признаки можно разделить на два типа: экспертные и нейросетевые. Их классификация показана на рисунке 3. Ниже приводится описание акустических признаков, используемых для анализа аффективных состояний.

Экспертные/ручные (англ. hand-crafted) наборы признаков основаны на знаниях об акустических свойствах речевых сигналов. Данные признаки обычно определяются на двух уровнях: сегментов аудиосигнала (или низкоуровневые дескрипторы, англ. Low Level Descriptor, LLD) и речевого высказывания. LLD извлекаются из коротких аудиосегментов и дают мгновенную информацию об аудиосигнале. Признаки на уровне высказывания получаются путем применения статистических функционалов к полученным дескрипторам.

Низкоуровневые дескрипторы можно условно разделить на следующие категории: энергетические, просодические, вокализованные и спектральные. Каждая группа показателей предназначена для описания отдельных аспектов голоса и находит свое применение при распознавании аффективных состояний. Просодические признаки отражают особенности речи, связанные с мелодическими, временными и тембровыми характеристиками голоса, а также ритмом высказывания. Вокализованные признаки отражают отклонения частоты сигнала (джиттер) и амплитуды (шimmer), отношение гармоник частоты основного тона (ЧОТ, англ. F0) к шуму. Данные характеристики качественно влияют на восприятие голоса. Спектральные признаки характеризуют речевой сигнал в его физическом и математическом смысле на основе наличия периодической (тональной) и непериодической (шумовой) спектральных составляющих. Они позволяют отразить особенности спектра голосовых импульсов, функции голосового тракта и динамику артикуляционных органов. Энергетические признаки передают информацию об уровне энергии аудиосигнала, и эффективны для распознавания интенсивности выраженной эмоции. Они могут быть выражены через сумму спектра, частоту нуль-пересечений и т.д.

Нейросетевые признаки автоматически извлекаются алгоритмами машинного обучения и часто не могут интерпретироваться людьми. Созданные признаки могут быть определены на двух разных уровнях: сегментов аудиосигнала и высказывания.

Наборы признаков openSMILE [47] фактически являются стандартом, используемым в качестве основы в различных задачах компьютерной паралингвистики [48]. В зависимости от конфигурации, набор признаков может включать в себя от 30 до 65 низкоуровневых дескрипторов: сумма акустических спектров (громкость); мел-частотные кепстральные коэффициенты (англ. Mel-Frequency Cepstral Coefficients, MFCC) 0-14; логарифмическая мощность Mel-частотных

полос 0-7 (распределенная в диапазоне от 0 до 8 кГц); отношение гармоника/шум, джиттер, шиммер; огибающая сглаженного контура F_0 с последующим сглаживанием Витерби; частота нуль-пересечений (англ. Zero-Crossing Rate) и т.д. Применение соответствующих производных к каждому дескриптору и функционалов (абсолютное положение максимального и минимального значения, стандартное отклонение, асимметрия, эксцесс, процентиля 1, 25, 50, 75 и 99 %, сглаженный контур F_0 , локальный и дифференциальный межкадровый джиттер и т.д.) дает вектор от 1428 до 6373 признаков.

Расширенный женеvский минималистический набор акустических параметров (англ. Extended Geneva Minimalistic Acoustic Parameter Set, eGeMAPS) – популярный набор признаков, разработанных вручную экспертами специально для распознавания эмоций по речи [49]. Он состоит из двух функциональных дескрипторов, среднего арифметического и коэффициента вариации набора из 42 дескрипторов.

Альтернативой вышеуказанным признакам, является использование алгоритмов машинного кодирования признаков, таких как BoAW (англ. Bag-of-Audio-Words) [50] и векторы Фишера (англ. Fisher Vectors, FV) [51]. В подходе BoAW выполняется кластеризация по 12 MFCC и логарифмической энергии сигнала. Список конечных центроидов кластера приводит к кодовой книге, которая используется для квантования исходных акустических LLD и присвоения их ближайшему (с точки зрения евклидова расстояния) звуковому слову в кодовой книге. Частоты звуковых слов используются для создания гистограммы, которая служит вектором признаков для классификации. FV обеспечивает надсегментное кодирование низкоуровневых дескрипторов, таких как MFCC и RASTA-образных коэффициентов перцептивного линейного предсказания (англ. Perceptual Linear Prediction, PLP), по их отклонению от распределения, которое можно смоделировать с помощью смеси гауссовых распределений (англ. Gaussian Mixture Model, GMM). Оба подхода успешно применяются для распознавания эмоций [50, 51].

Автоматическое извлечение признаков стало возможным с появлением нейронных сетей, способных анализировать представления признаков на ранних уровнях. Примерами являются нейросетевые наборы признаков Deep Spectrum [52], извлеченные с помощью глубокой нейронной сети, AuDeep, извлеченные с помощью архитектуры глубокой рекуррентной нейронной сети [53], и TRILL [54]. Также набирают популярность признаки, полученные с помощью Wav2Vec 2.0 [55].

Существует репозиторий алгоритмов обработки речи COVAREP (англ. Cooperative Voice Analysis Repository) [56], где исследователи могут хранить реализации опубликованных алгоритмов. Так создатели корпуса CMU-MOSEI [22] извлекли 12 MFCC, F0, функции сегментации (не)вокализованных звуков, параметры наклона пиков и коэффициенты дисперсии максимумов. Все выделенные признаки связаны с эмоциями и тоном речи.

Эффективность каждого типа признаков зависит от поставленной задачи: в то время как BoAW, Deep Spectrum и AuDeer потенциально способны превзойти функции openSMILE из-за большей гибкости и адаптивности, многие другие факторы, такие как размер выборки и шум, отрицательно влияют на производительность и эффективность обобщения. Показано, что признаки openSMILE демонстрируют более высокую производительность по сравнению с другими типами признаков на небольших наборах данных [48].

Вместо извлечения нескольких predetermined признаков часто используется подход «грубой силы», который извлекает огромное число всевозможных признаков. В результате вектор признаков достигает размерности сотен и тысяч компонентов. Даже если предположить, что каждый признак, входящий в такой набор, является информативным, не все элементы статистически независимы друг от друга. В таком случае, а также, когда данные неинформативны и, следовательно, избыточны, возникает необходимость уменьшения размерности признаков. После данной процедуры происходит неизбежная потеря исходной информации. Различные методы в разной степени сохраняют исходную информацию; наименьших потерь можно добиться с помощью метода главных компонент (англ. Principle Component Analysis, PCA) [57].

3.3. Текстовая модальность. Классификация методов представления лингвистических признаков. В данном разделе рассматриваются наиболее часто используемые методы лингвистических векторных представлений, полученных из транскрипций естественной речи в задачах распознавания эмоций, сентимента, агрессии и депрессии. На рисунке 3 показана классификация лингвистических признаков, они подразделяются на статистические и нейросетевые.

Словарные признаки [8] представляют собой набор статистических параметров для каждого слова, полученные из тональных и морфологических словарей. TF-IDF (англ. Term Frequency - Inverse Document Frequency) – отношение частоты слова в текущем документе к частоте этого же слова во всех документах.

Наиболее часто используются нейросетевые методы представления информации, такие как Word2Vec, FastText, Glove, Doc2Vec, BERT, подробное описание данных методов представлено в работе [8]. Некоторые признаки для векторизации текста являются комбинацией из различных методов. Так, например, часто используется CNN, на вход которой подаются Word2Vec или FastText [58], а также LSTM в комбинации с Glove [59].

3.4. Классификация методов распознавания аффективных состояний. Ранние системы автоматического распознавания аффективных состояний были основаны на методах k-ближайших соседей (англ. K-Nearest Neighbor, KNN) [60], GMM [61], скрытых марковских моделях (англ. Hidden Markov Model, HMM) [62], опорных векторов (англ. Support Vector Machine, SVM) [48], логистической регрессии (англ. Logistic Regression, LR) (рисунок 3).

С появлением больших объемов данных обучение подобных систем стало времязатратным процессом. Поэтому на смену им пришли полносвязные нейронные сети (англ. Fully Connected Network, FCN), в частности, однослойный перцептрон (англ. Single-Layer Perceptron, SLP) [63], машина экстремального обучения (англ. Extreme Learning Machine, ELM) [64] и многослойный перцептрон (англ. Multi-Layer Perceptron, MLP) [65]. Затем возникли глубокие нейронные сети (англ. Deep Neural Networks, DNN), которые с каждым годом эволюционируют и становятся все более производительными [66], в частности, активно стали использоваться нейросетевые архитектуры, основанные на сверточных (англ. Convolutional Neural Networks, CNN) и рекуррентных (англ. Recurrent Neural Networks, RNN) нейронных сетях [67]. Одна из разновидностей RNN, называемая моделью с долгой краткосрочной памятью (англ. Long Short-Term Memory, LSTM), особенно популярна благодаря своей способности моделировать большие временные последовательности [68]. В результате LSTM оказался более эффективной сетью, чем простые модели RNN для распознавания эмоций [69]. Другие варианты рекуррентных сетей, такие как двунаправленные RNN и LSTM были придуманы, чтобы иметь возможность моделировать не только предыдущий, но и будущий контекст [70]. RNN также часто сочетаются с другими типами нейронных сетей, например с CNN [71]. Механизм внимания (англ. Attention) – концепция, которая может использоваться в рекуррентных нейронных сетях для улучшения механизма памяти [72]. Он позволяет фокусироваться на наиболее важных признаках и отбрасывать менее важные. Самовнимание (англ. Self-Attention) – разновидность механизма внимания, задачей которой

является выявление закономерности только между входными данными. Данная методика показала себя настолько эффективной в задаче машинного перевода, что позволила отказаться от использования RNN и заменить их на обычные нейронные сети в комбинации с механизмом самовнимания в архитектуре трансформер (англ. Transformer) [73]. Это позволило ускорить работу алгоритма, поскольку теперь каждый фрагмент может обрабатываться параллельно, в отличие от последовательной обработки в RNN. Данный механизм успешно применяется и в приложениях распознавания аффективных состояний [74]. Известной моделью-трансформером для распознавания аффективных состояний является HuBert [75]. Однако данные подходы требуют большого количества обучающих данных, поэтому в сочетании с трансформерами часто используется метод переноса обучения (англ. Transfer Learning) [76]. Идея состоит в том, чтобы научить нейронную сеть выполнять одну задачу, где данных много, а затем настроить последние слои в предобученной сети для последующей целевой задачи. Это работает, потому что ранние слои нейронных сетей обычно анализируют представления признаков низкого уровня, которые являются общими для понимания речевых сигналов в целом. Известно, что методы анализа аудиомодальности лучше работают с активацией и доминацией [77] и имеют потенциал для обобщения на разные языки, однако обычно страдают от низкой точности распознавания валентности [78]. Предобученные Wav2Vec и HuBERT позволяют справиться с данной проблемой [55]. Существуют также интегральные (англ. End-to-end, E2E) методы, основанные на нейронных сетях, которые получая на вход сырой сигнал, без предварительной обработки позволяют предсказывать аффективные состояния [79], однако они требуют большого количества данных по сравнению с классическими подходами, которые включают в себя различные шаги по предобработке аудиосигнала и извлечению признаков.

3.5. Методы многомодального объединения информации.

Как было сказано выше, применение систем распознавания аффективных состояний человека с помощью только одной модальности (аудио, видео или текст) имеет ряд ограничений. Эти ограничения связаны как с техническими аспектами (неисправность камер, микрофонов и других сенсоров, высокий уровень шума и т.д.), так и с неоднозначностью интерпретации аффективных состояний исключительно по одному типу сигнала. Многочисленные источники литературы показывают, что валентность эмоции поддается моделированию с помощью акустических параметров значительно

хуже, чем активация [80]. То есть, довольно легко определить по голосу, спокоен или возбужден человек, но сложно однозначно сказать, в каком ключе: положительном или отрицательном. Такие эмоции, как счастье и злость имеют схожие акустические характеристики: повышение значения ЧОТ, высокая вариативность ЧОТ, повышение энергии в голосе и др. [7], что зачастую делает распознавание этих эмоций по голосу затруднительным. Для того, чтобы отличить эти эмоции, можно взглянуть на лицо человека и его мимику. Таким образом, одномодальный подход, использующий только один тип информации, обладает значительными ограничениями. Поведение человека складывается из речи, мимики и жестов. Восприятие этой информации у человека является многомодальным, т.е. осуществляется одновременно по нескольким каналам – визуальному, аудиальному, тактильному и т.д. Комбинирование двух и более модальностей позволяет значительно увеличить точность распознавания аффективных состояний [11], так как низкая точность работы системы классификации по одной модальности может компенсироваться высокой точностью по другой. Многомодальное распознавание также позволяет справиться с проблемой пропуска информации (когда в силу неисправности оборудования или плохого качества данных не удается использовать информацию от какой-либо модальности). Кроме того, многомодальный анализ позволяет зачастую распознавать и такие аффективные состояния, как сарказм и ирония, которые характеризуются явным несопадением смысла высказывания (анализ текста) с интонацией (анализ аудио) и мимикой (анализ видео). Следовательно, аудиовизуальный анализ характеристик диктора может значительно улучшить эффективность существующих систем распознавания аффективных состояний диктора.

Существуют несколько основных подходов к объединению аудио, видео и текстовой информации на различных уровнях: а) признаков, б) представлений признаков, в) моделей, г) гипотез предсказаний и д) гибридные модели [81]. На рисунке 4 схематично показаны подходы к объединению двух модальностей (на примере аудио и видео), однако, все представленные подходы являются легко масштабируемыми при добавлении новых модальностей.




Рис. 4. Основные подходы к многомодальному объединению информации

С точки зрения моделирования, способы объединения на уровне признаков (рисунок 4а) и представлений признаков (рисунок 4б) являются наиболее предпочтительными, так как позволяют одновременно учитывать не только различные аспекты одного и того же явления, но также и их взаимосвязи между собой. Это самый естественный способ обработки информации, по принципу которого работает человеческий мозг. Однако реализация такого объединения значительно затруднена, в частности, из-за различной природы акустических, визуальных и текстовых признаков, различного распределения этих признаков, проблем, связанных с различным количеством информации на единицу времени (частота вычисления векторов признаков) и синхронизацией сигналов. Использование общего набора признаков ведет к увеличению размерности признакового пространства, что при ограниченном объеме данных может сказаться на качестве распознавания в худшую сторону [82]. Объединение информации на уровне моделей на примере использования методов НММ показано на рисунке 4в. При таком подходе создаются две различные модели, которые обмениваются информацией и выдают общее предсказание. Применение данного подхода ограничено несколькими классификационными методами,

например, некоторыми видами НММ и нейронными сетями [83], однако другие методы классификации, например SVM, не подходят в виду того, что у них отсутствует механизм, принимающий во внимание состояния других классификационных моделей. Исследования показывают, что механизмы внимания широко используются и при объединении нескольких модальностей [84]. Наиболее простым и эффективным способом объединения информации от разных модальностей является объединение на уровне предсказаний/гипотез распознавания (рисунок 4г). Объединение предсказаний возможно как методом голосования (жесткая классификация), так и с помощью суммирования и/или взвешивания вероятностей (мягкая классификация) [85]. Такой подход имеет несколько важных преимуществ, например, не существует ограничений в выборе методов классификации, и для каждой модальности возможно подобрать оптимальный метод моделирования. Однако недостатком данного подхода является то, что он не учитывает взаимосвязи между различными модальностями, предполагая, что они независимы. Гибридные методы сочетают в себе сразу несколько описанных подходов к объединению информации [86].

В современных работах в области аффективных вычислений используются как классические экспертные методы, так и нейросетевые для извлечения признаков и классификации. Тенденция исследований показывает, что нейросетевые методы постепенно вытесняют экспертные, за счет достижения большей точности распознавания аффективных состояний и быстрой обработки больших объемов данных. Многомодальный подход для автоматического анализа аффективных состояний позволяют повысить точность распознавания аффектов.

4. Методы для распознавания аффективных состояний.

В данном разделе рассматриваются актуальные исследования, в которых применяются методы распознавания эмоций, сентимента и агрессии. Методы распознавания депрессии детально рассмотрены в работе [9].

4.1. Эмоции и сентимент. Для сравнительного анализа рассмотрены экспериментальные исследования, проводимые только на англоязычном многомодальном корпусе CMU-MOSEI [22]. К преимуществам данного корпуса можно отнести: разметку одновременно и по эмоциям, и по сентименту; натурные условия записи и спонтанную речь информантов; максимально доступное число участников (1000); преимущественно один участник в кадре; деление записей на полные высказывания. В различных работах

классификация сентимента проводилась по нескольким классам: 2 (негативный, позитивный), 3 (негативный, нейтральный, позитивный), 5 (сильно негативный, негативный, нейтральный, позитивный, сильно позитивный) и 7 классов (от -3 до 3), в соответствии с разметкой авторов CMU-MOSEI. В таблице 5 представлен сравнительный анализ автоматических систем распознавания эмоций и сентимента на корпусе CMU-MOSEI. В таблице действуют следующие обозначения: В – видео, А – аудио, Т – текст, WAcc – взвешенная точность, WF – взвешенная F-мера, m – среднее значение WAcc и WF по 6 классам (таблица 5).

Во многих работах в качестве акустических, визуальных и лингвистических признаков использовались методы COVAREP, Facets и Glove, соответственно. Для данных корпуса CMU-MOSEI все признаки находятся в открытом доступе (<https://github.com/A2Zadeh/CMU-MultimodalSDK>).

Методы классификации условно можно разделить на группы в зависимости от используемых в них нейросетевых моделей: графовые нейронные сети – Graph Memory Fusion Network (Graph-MFN) [22] и Adversarial Representation Graph Fusion (ARGF) [87]; рекуррентные нейронные сети – Multi-Modal Multi-Utterance - Bi-Modal Attention (MMM-BA) [88], Multi-task Multi-modal Emotion and Sentiment (MTMM-ES) [89], Interaction Canonical Correlation Network (ICCN) [90], Hierarchical Feature Fusion Network (HFFN) [91] и Inter-modal Interactive Module for Multi-modal Sentiment and Emotion Recognition (IIM-MMSE) [92]; трансформеры – Transformer-Based Joint-Encoding (TBJE) [93] и Multimodal Transformer (MulT) [94]. Наибольшая точность по показателю mWAcc для бинарного распознавания 6 категорий эмоций достигается с помощью методов классификации на основе моделей трансформеров TBJE и MulT. Причиной этого является использование не только трансформеров, но также CNN для представления визуальных признаков, мел-спектрограммы и банк лог-фильтров энергии (англ. Log-Filter bank energy) – для акустических признаков. Кроме того, с помощью TBJE удалось достичь наибольшей точности распознавания 2 классов сентимента по показателю WAcc, а с помощью методов классификации на основе рекуррентных нейросетей IIM-MMSE [92] и ICCN [90] для 5 и 7 классов сентимента, соответственно.

Таблица 5. Сравнительный анализ автоматических систем распознавания эмоций и сентимента

Работа	Признаки (В; А; Т)	Метод классификации	Качество распознавания (%)				
			Эмоции		Сентимент		
			mWAcc	mWF	Число классов	WAcc	WF
Khare A. и др. [94]	CNN; банк лог-фильтров энергии; Glove	MuT	67,4	78,6	-	-	-
Zadeh A. и др. [22]	Facets, OpenFace, CNN; COVAREP; Glove	Graph-MFN	62,3	76,3	2	76,9	77,0
					5	45,1	-
					7	45,0	-
Chauhan D.S. и др. [92]	-	ИМ-MMSE	63,0	79,0	2	80,4	78,2
					5	49,2	-
					7	50,1	-
Delbrouck J.B. и др. [93]	CNN; Мел-спектрограммы; Glove	TBJE	80,7	76,7	2	81,5	-
					7	44,4	-
Sun Z. и др. [90]	Facets; COVAREP; BERT	ICCN	-	-	7	51,6	-
Akhtar M.S. и др. [89]	Facets; COVAREP; Glove	MTMM-ES	62,8	78,6	2	80,5	78,8
Ghosal D. и др. [88]		MMMU-BA	-	-	2	79,8	-
Mai S. и др. [91]		HFFN	-	-	3	60,4	59,1
Mai S. и др. [87]		ARGF	-	-	3	60,9	59,5

Таким образом, большей точности распознавания эмоций и сентимента можно достичь с использованием машинной классификации на основе моделей рекуррентных нейросетей и трансформеров.

4.2. Агрессия. Ряд работ посвящен распознаванию вербальной агрессии в тексте. В работах [95, 96] рассматриваются методы распознавания агрессии на основе правил и словарей. В работе [97] сведены основные результаты классических методов машинного обучения для распознавания агрессии в тексте: логистической регрессии, случайного леса, ансамблевого классификатора, SVM, а также приводятся современные подходы глубокого обучения для распознавания агрессии в тексте. При этом в ряде работ рассматриваются также различные виды агрессии, которые проявляются в тексте. Выделяют прямую/косвенную [98] агрессию, а также различные разновидности прямой вербальной агрессии в тексте: проявления ненависти, оскорбления и сквернословия [99].

Работы, посвященные распознаванию агрессии по невербальному речевому поведению в аудиосигнале, можно разделить на те, которые рассматривают классические методы машинного обучения и методы, использующие глубокие нейронные сети. Классические методы машинного обучения отражены в работах [100], раскрывающих классификацию спектральных признаков посредством SVM. В работе [101] представлена классификация главных компонент спектра давления воздуха посредством НММ. Применение глубоких CNN, обрабатывающих мел-спектрограммы рассмотрено в работе [102].

Системы распознавания агрессии в поведенческой активности на видео разделяются на те, которые рассматривают сконструированные вручную дескрипторы и классические алгоритмы машинного обучения [31] и методы обработки видео глубокими нейронными сетями [103]. Подавляющее количество работ из данной категории направлены на распознавание агрессии людей, записанной на камеры внешнего видеонаблюдения.

Среди многомодальных методов распознавания агрессии выделяют методы, использующие в своей основе подходы онтологического моделирования вместе с классическими алгоритмами машинного обучения [27], а также подходы глубокого обучения [104]. На рисунке 5 изображена классификация методов распознавания агрессии пользователей.

Таким образом, на основе анализа приведенных работ выделяются основные группы методов и моделей распознавания агрессии. Можно выделить следующие критерии для классификации методов и моделей: 1) по модальности; 2) по виду распознаваемой агрессии; 3) по методу распознавания.

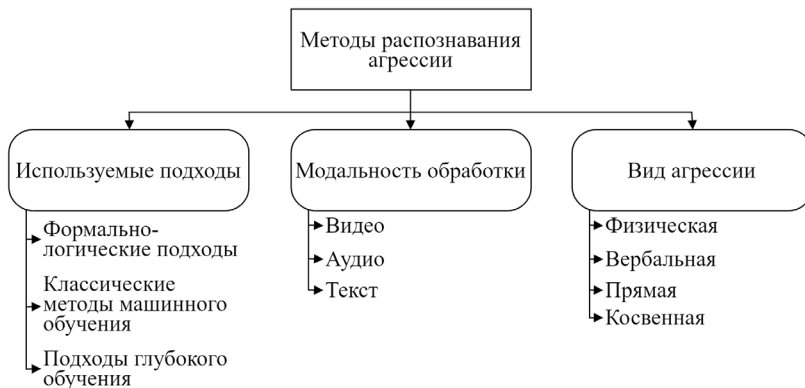


Рис. 5. Классификация методов распознавания агрессии

4.3. Многозадачные системы. Многозадачные (англ. multi-task) системы предполагают распознавание нескольких аффективных состояний. Зачастую такие системы являются и многомодальными, например, при распознавании эмоций и анализа сентимента [89]. Последний, в свою очередь, определяется, в большинстве случаев, по текстовой модальности [8], в отличие от эмоций, которые можно определить по тексту, аудио и видео. Поэтому многозадачные системы схожи с многомодальным объединением информации на уровне моделей (рисунок 4в) [89]. Существуют два основных подхода к разработке многозадачных систем классификации и регрессии: 1) использование общих параметров, 2) использование общих, и собственных параметров для каждой задачи. Архитектуры данных моделей представлены на рисунке 6. Количество выходных данных (предсказаний) увеличивается соответственно количеству классов рассматриваемых аффективных состояний, и можно одновременно решать задачи классификации и регрессии [105].

Общая часть системы обычно состоит из различных видов рекуррентных слоев, которые способны улавливать контекст. Этими слоями могут быть LSTM [106], GRU (англ. Gated Recurrent Unit) [107], BiLSTM [108] и др. Одним из ключевых этапов при разработке многозадачной системы обучения является определение целевой функции обучения, т.е. функции потерь. Многозадачная экспериментальная установка предполагает распознавание нескольких аффективных состояний, поэтому функция потерь должна одинаково учитывать ошибки распознавания всех рассматриваемых задач, что обуславливает необходимость разрабатывать сложную составную

функцию потерь, учитывающую несколько факторов. Это может быть взвешенная сумма нескольких целевых функций, каждая из которых отвечает за свою задачу [107-109]. Механизм внимания также применяется в многозадачных системах [108].




Рис. 6. Многозадачные нейросетевые архитектуры: а) полностью общие для всех корпусов данных, б) частично общие для всех корпусов данных

Использование нескольких корпусов является многозадачным подходом, так как корпуса могут содержать неоднородные данные [110]. Проблема может встречаться при разработке многомодальных многозадачных систем в контексте одного корпуса в условиях отсутствия меток для одной из задач или модальностей [109].

Многозадачные системы могут быть и иерархическими, которые отличаются последовательным моделированием нескольких аффективных состояний, причем на каждом последующем этапе используются результаты распознавания предыдущего этапа [111]. Пример иерархической структуры для распознавания аффективных состояний показан на рисунке 7.

Преимуществом использования многозадачных и иерархических подходов к распознаванию аффективных состояний является возможность извлекать новые типы знаний, в том числе о влиянии, корреляции и взаимодействии нескольких аффективных состояний друг на друга, что потенциально влечет к улучшению качества распознавания.

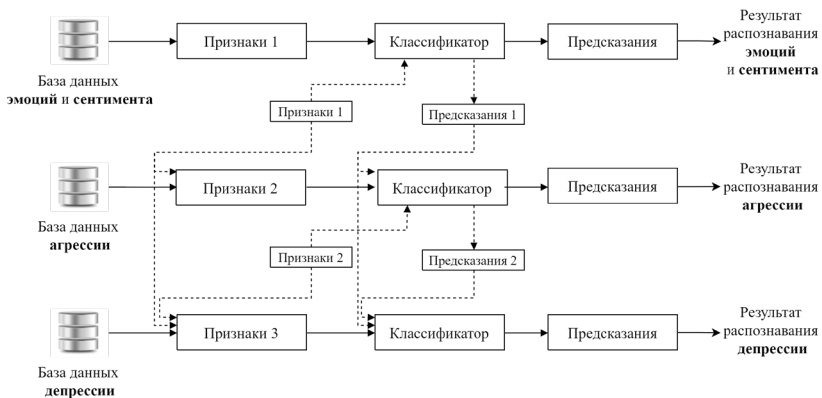


Рис. 7. Архитектура для иерархического распознавания множественных аффективных состояний

Можно сделать вывод, что область анализа эмоций и сентимента достаточно развита, существует большое количество эмоциональных и сентимент корпусов как одномодальных, так и многомодальных, а автоматические системы достигают точности около 80% распознавания эмоций и сентимента. Однако задача распознавания депрессии и агрессии значительно уступает эмоциональному распознаванию в объеме и качестве информационного и математического обеспечения. Многозадачных систем, которые распознают одновременно все четыре основных аффективных состояния (эмоции, сентимент, агрессия и депрессия), пока не существует.

5. Заключение. Исходя из аналитического обзора, можно сделать вывод, что не существует эффективных систем для одновременного распознавания различных аффективных состояний человека, поэтому ставится задача разработки автоматической программной системы, которая будет удовлетворять следующим основным требованиям:

- 1) Анализировать визуальную, акустическую и лингвистическую информацию (многомодальность).
- 2) Распознавать 4 основных аффективных состояния: эмоции, сентимент, агрессию и депрессию (многозадачность).
- 3) Иметь высокую точность распознавания различных видов аффектов, не менее 80% для каждого вида аффекта.
- 4) Работать в режиме близком к реальному времени.

5) Проводить обучение и тестирование системы на данных, полученных в реальных условиях.

Для обучения вероятностных моделей планируется использовать многомодальные корпуса CMU-MOSEI, RAMAS и DAIC, ориентированные на распознавание эмоций, сентимента и депрессии. Преимущество корпуса CMU-MOSEI заключается в том, что он имеет разметку данных на эмоции и сентимент одновременно, корпус RAMAS является единственным русскоязычным ресурсом в данной области. Корпус DAIC является самым репрезентативным информационным ресурсом по сравнению с другими многомодальными корпусами для анализа депрессии, поэтому он также будет использован для дальнейших исследований. Для решения задачи распознавания агрессии планируется собрать и аннотировать собственную базу данных.

Все это позволит разработать систему автоматического распознавания аффективных состояний человека на основе многомодального и многозадачного подхода. Аудио-, видео- и текстовые модальности оказались наиболее репрезентативными для анализа аффективных состояний. Это приводит к выводу, что данные модальности необходимо использовать в рамках многомодального подхода, предполагающего слияние модальностей на уровне прогнозов. Использование иерархического подхода для распознавания различных аффективных состояний позволит повысить эффективность работы разрабатываемой системы. Иерархия заключается в распознавании эмоций и сентимента на первом шаге, а затем полученные результаты используются для распознавания агрессии и/или депрессии. Такая система может быть использована в колл-центрах для мониторинга эмоционального состояния операторов и клиентов, в автомобилях для определения агрессивного состояния водителя, в медицинских организациях для выявления депрессивного состояния больных.

Литература

1. Picard R.W. Affective Computing for HCI // HCI (1). 1999. С. 829-833.
2. Вилонас В.К. Эмоции // Большой психологический словарь / Под общ. ред. Б.Г. Мещерякова, В.П. Зинченко // СПб.: Прайм-ЕВРОЗНАК. 2007. С. 565-568.
3. Крафт-Эбинг Р. Учебник психиатрии. 1897. 698 с.
4. Ильин Е.П. Эмоции и чувства. Издательский дом "Питер". 2011. 782 с.
5. Тхостов А.Ш., Колымба И.Г. Эмоции и аффекты: общепсихологический и патологический аспекты // Психологический журнал. 1998. № 4. С. 41-48.
6. Ениколопов С.Н. Понятие агрессии в современной психологии // Прикладная психология. 2001. №. 1. С. 60-72.
7. Верхоляк О.В., Карпов А.А. Глава «Автоматический анализ эмоционально окрашенной речи» в монографии «Голосовой портрет ребенка с типичным и

- атипичным развитием» // Е.Е. Ляксо, О.В. Фролова, С.В. Гречаний, Ю.Н. Матвеев, О.В. Верхоляк, А.А. Карпов / под ред. Е.Е. Ляксо, О.В. Фроловой // СПб. Изд-во: Издательско-полиграфическая ассоциация высших учебных заведений. 2020. С. 204.
8. Двойникова А.А., Карпов А.А. Аналитический обзор подходов к распознаванию тональности русскоязычных текстовых данных // Информационно-управляющие системы. 2020. №. 4 (107). С. 20-30.
 9. Величко А.Н., Карпов А.А. Аналитический обзор систем автоматического определения депрессии по речи. Информатика и автоматизация. №20. 2021. С. 497-529.
 10. American Psychiatric Association. Diagnostic and Statistical Manual of Mental Disorders (DSM-5). American Psychiatric Publishing, Arlington, VA. 2013.
 11. Tzirakis P., Trigeorgis G., Nicolaou M.A., et al. End-to-end multimodal emotion recognition using deep neural networks // IEEE Journal of Selected Topics in Signal Processing. 2017. vol. 11. no. 8. pp. 1301-1309.
 12. Dhall A., Goecke R., Gedeon T. Collecting large, richly annotated facial-expression databases from movies // IEEE Multimedia. 2012. vol. 19. no. 03. pp. 34-41.
 13. Kossaifi J., Tzimiropoulos G., Todorovic S., et al. AFEW-VA database for valence and arousal estimation in-the-wild // Image and Vision Computing. 2017. vol. 65. pp. 23-36.
 14. Kollias D., Zafeiriou S. Aff-wild2: Extending the aff-wild database for affect recognition // arXiv preprint arXiv:1811.07770. 2018.
 15. Lien J.J., Kanade T., Cohn J.F., et al. Automated facial expression recognition based on FACS action units // Proceedings of third IEEE international conference on automatic face and gesture recognition. IEEE. 1998. pp. 390-395.
 16. Busso C., Bulut M., Lee C.-C., et al. IEMOCAP: Interactive emotional dyadic motion capture database // Language Resources and Evaluation. 2008. vol. 42. no. 4. pp. 335-359.
 17. Ringeval F., Sonderegger A., Sauer J., et al. Introducing the RECOLA multimodal corpus of remote collaborative and affective interactions // Proceedings of the 2013 10th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG). IEEE. 2013. pp. 1-8.
 18. Kossaifi J., Walecki R., Panagakis Y., et al. SEWA DB: A Rich Database for Audio-Visual Emotion and Sentiment Research in the Wild // IEEE Transactions on Pattern Analysis & Machine Intelligence. 2021. vol. 43. no. 03. pp. 1022-1040.
 19. McKeown G., Valstar M.F., Cowie R., et al. The SEMAINE corpus of emotionally coloured character interactions // Proceedings of the IEEE International Conference on Multimedia and Expo. IEEE. 2010. pp. 1079-1084.
 20. Perepelkina O., Kazimirova E., Konstantinova M. RAMAS: Russian multimodal corpus of dyadic interaction for affective computing // Proceedings of the International Conference on Speech and Computer. Springer, Cham. 2018. pp. 501-510.
 21. Poria S., Hazarika D., Majumder N., et al. Meld: A multimodal multi-party dataset for emotion recognition in conversations // Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019. pp. 527-536.
 22. Zadeh A.B., Liang P.P., Poria S., et al. Multimodal Language Analysis in the Wild: CMU-MOSEI Dataset and Interpretable Dynamic Fusion Graph // Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. 2018. pp. 2236-2246.
 23. Pérez-Rosas V., Mihalcea R., Morency L.P. Utterance-level multimodal sentiment analysis // Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics. vol. 1. 2013. pp. 973-982.

24. Zadeh A., Zellers R., Pincus E., et al. Multimodal Sentiment Intensity Analysis in Videos: Facial Gestures and Verbal Messages // *IEEE Intelligent Systems*. 2016. vol. 31. no. 6. pp. 82-88.
25. Morency L.P., Mihalcea R., Doshi P. Towards multimodal sentiment analysis: Harvesting opinions from the web // *Proceedings of the 13th International Conference on Multimodal Interfaces*. 2011. pp. 169-176.
26. Yu W., Xu H., Meng F., et al. Ch-sims: A chinese multimodal sentiment analysis dataset with fine-grained annotation of modality // *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*. 2020. pp. 3718-3727.
27. Lefter I., Rothkrantz L.J.M., Burghouts G., et al. Addressing multimodality in overt aggression detection // *Proceedings of the International Conference on Text, Speech and Dialogue*. Springer, Berlin, Heidelberg. 2011. pp. 25-32.
28. Lefter I., Burghouts G.J., Rothkrantz L.J.M. An audio-visual dataset of human-human interactions in stressful situations // *Journal on Multimodal User Interfaces*. 2014. vol. 8. no. 1. pp. 29-41.
29. Lefter I., Rothkrantz L.J.M. Multimodal cross-context recognition of negative interactions // *Proceedings of the Seventh International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*. IEEE. 2017. pp. 56-61.
30. Lefter I., Jomker C.M., Tuentje S.K., et al. NAA: A multimodal database of negative affect and aggression // *Proceedings of the Seventh International Conference on Affective Computing and Intelligent Interaction (ACII)*. IEEE. 2017. pp. 21-27.
31. Nieves E.B., Déniz-Suárez O., Garcia G., et al. Violence detection in video using computer vision techniques // *Proceedings of the International conference on Computer analysis of images and patterns*. Springer, Berlin, Heidelberg. 2011. pp. 332-339.
32. Perez M., Kot A.C., Rocha A. Detection of real-world fights in surveillance videos // *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE. 2019. pp. 2662-2666.
33. Cheng M., Cai K., Li M. Rwf-2000: An open large scale video database for violence detection // *Proceedings of the 25th International Conference on Pattern Recognition (ICPR)*. IEEE. 2021. pp. 4183-4190.
34. Kumar R., Reganti A.N., Bhatia A., et al. Aggression-annotated corpus of hindi-english code-mixed data // *arXiv preprint arXiv:1803.09402*. 2018.
35. Bozyiğit A., Utku S., Nasibov E. Cyberbullying detection: Utilizing social media features // *Expert Systems with Applications*. 2021. vol. 179. p. 115001.
36. Gratch J., Artstein R., Lucas G., et al. The Distress Analysis Interview Corpus of Human and Computer Interviews // *Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14)*. Reykjavik, Iceland. 2014. pp. 3123-3128.
37. Valstar M., Schuller B., Smith K., et al. AVEC 2013: the continuous audio/visual emotion and depression recognition challenge // *Proceedings of the 3rd ACM international workshop on Audio/visual emotion challenge (AVEC'13)*. Association for Computing Machinery, New York, NY, USA. 2013. pp. 3-10.
38. Yang Y., Fairbairn C., Cohn J. Detecting depression severity from vocal prosody // *IEEE Transactions on Affective computing*. 2013. vol. 4. no. 2. pp. 142-150.
39. Alghowinem S., Goecke R., Wagner M., et al. From joyous to clinically depressed: Mood detection using spontaneous speech // *Proceedings of FLAIRS Conference*, G.M. Youngblood and P.M. McCarthy, Eds. AAAI Press. 2012. pp. 141-146.
40. Huang Z., Epps J., Joachim D., et al. Depression detection from short utterances via diverse smartphones in natural environmental conditions // *Proceedings of Interspeech*. 2018. pp. 3393-3397.

41. Ryumina E., Karpov A. Facial expression recognition using distance importance scores between facial landmarks // CEUR Workshop Proceedings. 2020, vol. 274. pp. 1-10.
42. Axyonov, A., Ryumin, D., Kagirow, I. Method of Multi-Modal Video Analysis of Hand Movements for Automatic Recognition of Isolated Signs of Russian Sign Language // Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. 2021. vol. XLIV-2/W1-2021. pp. 7–13.
43. He K., Zhang X., Ren S., et al. Deep residual learning for image recognition // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. pp. 770–778.
44. Simonyan K., Zisserman A. Very deep convolutional networks for largescale image recognition // Proceedings of the 3rd International Conference on Learning Representations (ICLR). 2015. pp. 1–14.
45. Niu B., Gao Z., Guo B. Facial expression recognition with LBP and ORB features // Computational Intelligence and Neuroscience. 2021. vol. 2021.
46. Verma S., Wang J., Ge Zh., et al. Deep-HOSeq: Deep higher order sequence fusion for multimodal sentiment analysis // Proceedings of IEEE International Conference on Data Mining (ICDM). IEEE. 2020. pp. 561-570.
47. Eyben F., Weninger, F., Gross, F., et al. Recent developments in opensmile, the munich open-source multimedia feature extractor // Proceedings of ACM International Conference on Multimedia. 2013. pp. 835–838.
48. Schuller B.W., Batliner A., Bergler C., et al. The INTERSPEECH 2021 Computational Paralinguistics Challenge: COVID-19 Cough, COVID-19 Speech, Escalation & Primate // Proceedings of Interspeech. 2021. pp. 431–435.
49. Eyben F., Scherer K.R., Schuller, B.W., et al. The Geneva minimalistic acoustic parameter set (GeMAPS) for voice research and affective computing // IEEE transactions on affective computing. 2015. vol. 7. no. 2. pp. 190–202.
50. Schmitt M., Ringeval F., Schuller B.W. At the border of acoustics and linguistics: Bag-of-Audio-Words for the recognition of emotions in speech // Proceedings of Interspeech. 2016. pp. 495–499.
51. Kaya H., Karpov A.A., Salah A.A. Fisher vectors with cascaded normalization for paralinguistic analysis // Proceedings of Interspeech. 2015. pp. 909–913.
52. Zhao Z., Zhao Y., Bao Z., et al. Deep spectrum feature representations for speech emotion recognition // Proceedings of Workshop on Affective Social Multimedia Computing and First Multi-Modal Affective Computing of Large-Scale Multimedia Data. 2018. pp. 27–33.
53. Freitag M., Amiriparian S., Pugachevskiy S., et al. AuDeep: Unsupervised learning of representations from audio with deep recurrent neural networks // The Journal of Machine Learning Research. 2017. vol. 18. no. 1. pp. 6340–6344.
54. Shor J., Jansen A., Maor R., et al. Towards Learning a Universal Non-Semantic Representation of Speech // Proceedings of Interspeech. 2020. pp. 140–144.
55. Wagner J., Triantafyllopoulos A., Wierstorf H., et al. Dawn of the transformer era in speech emotion recognition: closing the valence gap // arXiv preprint arXiv:2203.07378. 2022. pp. 1-25.
56. Degottex G., Kane J., Drugman T., et al. COVAREP – A collaborative voice analysis repository for speech technologies // Proceedings of International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2014. pp. 960-964.
57. Sogancioglu G., Verkholiyak O., Kaya H., et al. Is Everything Fine, Grandma? Acoustic and Linguistic Modeling for Robust Elderly Speech Emotion Recognition // Proceedings of Interspeech. 2020. pp. 2097-2101.
58. Sebastian J., Pierucci P. Fusion Techniques for Utterance-Level Emotion Recognition Combining Speech and Transcripts // Proceedings of Interspeech. 2019. pp. 51-55.

59. Xu H., Zhang H., Han K., et al. Learning alignment for multimodal emotion recognition from speech // arXiv preprint arXiv:1909.05645. 2019.
60. Dellaert F., Polzin T., Waibel A. Recognizing emotion in speech // Proceedings of the 4th Int. Conf. Spoken Lang. Process (ICSLP). 1996. pp. 1970–1973.
61. Neiberg D., Elenius K., Laskowski K. Emotion recognition in spontaneous speech using GMMs // Proceedings of the 9th Int. Conf. Spoken Lang. Process. 2006. pp. 809–812.
62. Nogueiras A., Moreno A., Bonafonte A., et al. Speech emotion recognition using hidden Markov models // Proceedings of the 7th Eur. Conf. Speech Commun. Technol. 2001. pp. 746–749.
63. Raudys Š. On the universality of the single-layer perceptron model // Neural Networks and Soft Computing. Physica, Heidelberg. 2003. pp. 79–86.
64. Wang J., Lu S., Wang S.-H., et al. A review on extreme learning machine // Multimedia Tools and Applications. 2021. pp. 1–50.
65. Kruse R., Borgelt C., Klawonn F., et al. Multi-layer perceptrons // Computational Intelligence. Springer, Cham. 2022. pp. 53–124.
66. Sainath T.N., Vinyals O., Senior A., et al. Convolutional, long short-term memory, fully connected deep neural networks // Proceedings of International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2015. pp. 4580–4584.
67. Kim J., Truong K.P., Englebienne G., et al. Learning spectro-temporal features with 3D CNNs for speech emotion recognition // Proceedings of the 7th International Conference on Affective Computing and Intelligent Interaction (ACII). 2017. pp. 383–388.
68. Chao L., Tao J., Yang M., et al. Long short term memory recurrent neural network based multimodal dimensional emotion recognition // Proceedings of the 5th International Workshop on Audio/Visual Emotion Challenge. 2015. pp. 65–72.
69. Wang J., Xue M., Culhane R., et al. Speech emotion recognition with dual-sequence lstm architecture // Proceedings of International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2020. pp. 6474–6478.
70. Chen Q., Huang, G. A novel dual attention-based blstm with hybrid features in speech emotion recognition // Engineering Applications of Artificial Intelligence. 2021. vol. 102. p. 104277.
71. Zhao J., Mao X., Chen L. Speech emotion recognition using deep 1d & 2d cnn lstm networks // Biomedical Signal Processing and Control. 2019. vol. 47. pp. 312–323.
72. Milner R., Jalal M.A., Ng R.W., et al. A cross-corpus study on speech emotion recognition // Proceedings of IEEE Automatic Speech Recognition and Understanding Workshop (ASRU). 2019. pp. 304–311.
73. Vaswani A., Shazeer N., Parmar N., et al. Attention is all you need // In Proceedings of 31st Conference on Neural Information Processing Systems (NIPS 2017). 2017. vol. 30. pp. 1–11.
74. Ho N.H., Yang H.J., Kim S.H., et al. Multimodal approach of speech emotion recognition using multi-level multi-head fusion attention-based recurrent neural network // IEEE Access. 2020. vol. 8. pp.61672–61686.
75. Hsu W.N., Bolte B., Tsai Y.-H.H., et al. Hubert: Self-supervised speech representation learning by masked prediction of hidden units // IEEE/ACM Transactions on Audio, Speech, and Language Processing. 2021. vol. 29. pp. 3451–3460.
76. Siriwardhana S., Reis A., Weerasekera R., et al. Jointly fine-tuning “bert-like” self-supervised models to improve multimodal speech emotion recognition // arXiv preprint arXiv:2008.06682. 2020. pp. 1–5.
77. Kratzwald B., Ilic S., Kraus M., et al. Deep learning for affective computing: Text-based emotion recognition in decision support // Decision Support Systems. 2018. vol. 115. pp. 24–35.

78. Stappen L., Baird A., Christ L., et al. The muse 2021 multimodal sentiment analysis challenge: Sentiment, emotion, physiological-emotion, and stress // Proceedings of the 29th ACM International Conference on Multimedia (ACM MM). 2021. pp. 5706–5707.
79. Dresvyanskiy D., Ryumina E., Kaya H., et al. 2022. End-to-End Modeling and Transfer Learning for Audiovisual Emotion Recognition in-the-Wild // Multimodal Technologies and Interaction. vol 6. no. 2. pp. 11.
80. Fedotov D., Kaya H., Karpov A. Context Modeling for Cross-Corpus Dimensional Acoustic Emotion Recognition: Challenges and Mixup // Proceedings of 20th International Conference on Speech and Computer (SPECOM-2018). 2018. pp. 155-165.
81. Wu C.H., Lin J.C., Wei W.L. Survey on audiovisual emotion recognition: databases, features, and data fusion strategies // APSIPA Transactions on Signal and Information Processing. 2014. vol. 3. pp. 18.
82. Al Osman H., Falk T.H. Multimodal affect recognition: Current approaches and challenges // Emotion and Attention Recognition Based on Biological Signals and Images. 2017. pp. 59-86.
83. Liu D., Wang Z., Wang L., et al. Multi-Modal Fusion Emotion Recognition Method of Speech Expression Based on Deep Learning // Frontiers in Neurorobotics. 2021. pp. 13.
84. Zhang C., Yang Z., He X., et al. Multimodal intelligence: Representation learning, information fusion, and applications // IEEE Journal of Selected Topics in Signal Processing. 2020. vol. 14. no. 3. pp. 478-493.
85. Markitantov M., Ryumina E., Ryumin D., et al. Biometric Russian Audio-Visual Extended MASKS (BRAVE-MASKS) Corpus: Multimodal Mask Type Recognition Task // Proceedings of Interspeech. 2022. pp. 1756-1760.
86. Yang L., Sahli H., Xia X., et al. Hybrid depression classification and estimation from audio video and text information // Proceedings of 7th Annual Workshop on Audio/Visual Emotion Challenge (AVEC). 2017. pp. 45-51.
87. Mai S., Hu H., Xing S. Modality to modality translation: An adversarial representation learning and graph fusion network for multimodal fusion // Proceedings of the AAAI Conference on Artificial Intelligence. 2020. vol. 34. no. 01. pp. 164-172.
88. Ghosal D., Akhtar M.S., Chauhan D., et al. Contextual inter-modal attention for multimodal sentiment analysis // Proceedings of the Conference on Empirical Methods in Natural Language Processing. 2018. pp. 3454-3466.
89. Akhtar M.S., Chauhan D.S., Ghosal D., et al. Multi-task learning for multi-modal emotion recognition and sentiment analysis // arXiv preprint arXiv:1905.05812. 2019. pp. 1-10.
90. Sun Z., Sarma P, Sethares W., et al. Learning relationships between text, audio, and video via deep canonical correlation for multimodal language analysis // Proceedings of the AAAI Conference on Artificial Intelligence. 2020. vol. 34. no. 05. pp. 8992-8999.3.
91. Mai S., Hu H., Xing S. Divide, conquer and combine: Hierarchical feature fusion network with local and global perspectives for multimodal affective computing // Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019. pp. 481-492.
92. Chauhan D.S., Akhtar M.S., Ekbal A., et al. Context-aware interactive attention for multi-modal sentiment and emotion analysis // Proceedings of the Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). 2019. pp. 5647-5657.

93. Delbrouck J.B., Tits N., Brousmiche M., et al. A transformer-based joint-encoding for emotion recognition and sentiment analysis // arXiv preprint arXiv:2006.15955. 2020.
94. Khare A., Parthasarathy S., Sundaram S. Self-Supervised learning with cross-modal transformers for emotion recognition // IEEE Spoken Language Technology Workshop (SLT). IEEE. 2021. pp. 381-388.
95. Zaib S., Asif M., Arooj M. Development of Aggression Detection Technique in Social Media // International Journal of Information Technology and Computer Science. 2019. vol. 5. no. 8. pp. 40-46.
96. Левоневский Д.К., Савельев А.И. Подход и архитектура для систематизации и выявления признаков агрессии в русскоязычном текстовом контенте // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2021. № 54. С. 56-64.
97. Sadiq S., Mehmood A., Ullah S., et al. Aggression detection through deep neural model on twitter // Future Generation Computer Systems. 2021. vol. 114. pp. 120-129.
98. Tommasel A., Rodriguez J.M., Godoy D. Textual Aggression Detection through Deep Learning // TRAC@ COLING 2018. 2018. pp. 177-187.
99. Mandl T., Modha S., Shahi G.K., et al. Overview of the hasoc subtrack at fire 2021: Hate speech and offensive content identification in english and indo-aryan languages // arXiv preprint arXiv:2112.09301. 2021.
100. Potharaju Y., Kamsali M., Kesavari C.R. Classification of Ontological Violence Content Detection through Audio Features and Supervised Learning // International Journal of Intelligent Engineering and Systems. 2019. vol. 12. no. 3. pp. 20-30.
101. Sahoo S., Routray A. Detecting aggression in voice using inverse filtered speech features // IEEE Transactions on Affective Computing. 2016. vol. 9. no. 2. pp. 217-226.
102. Santos F., Durães D., Marcondes F.M., et al. In-car violence detection based on the audio signal // Proceedings of the International Conference on Intelligent Data Engineering and Automated Learning. Springer, Cham. 2021. pp. 437-445.
103. Liang Q., Li Y., Chen B., et al. Violence behavior recognition of two-cascade temporal shift module with attention mechanism // Journal of Electronic Imaging. 2021. vol. 30. no. 4. pp. 043009.
104. Уздяев М.Ю. Нейросетевая модель многомодального распознавания человеческой агрессии // Вестник КРАУНЦ. Физико-математические науки. 2020. Т. 33. №. 4. С. 132-149.
105. Yao Y., Papakostas M., Burzo M., et al. MUSER: MULTimodal Stress detection using Emotion Recognition as an Auxiliary Task // Proceedings of Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT). 2021. pp. 2714-2725.
106. Sangwan S., Chauhan D.S., Akhtar M., et al. December. Multi-task gated contextual cross-modal attention framework for sentiment and emotion analysis // Proceedings of International Conference on Neural Information Processing. 2019. pp. 662-669.
107. Kollias D., Zafeiriou S. Expression, affect, action unit recognition: Aff-wild2, multi-task learning and arcfac // arXiv preprint arXiv:1910.04855. 2019. pp. 1-15.
108. Li Y., Zhao T., Kawahara T. Improved End-to-End Speech Emotion Recognition Using Self Attention Mechanism and Multitask Learning // Proceedings of Interspeech. 2019. pp. 2803-2807.
109. Yu W., Xu H., Yuan Z., et al. Learning modality-specific representations with self-supervised multi-task learning for multimodal sentiment analysis // Proceedings of the AAAI Conference on Artificial Intelligence. 2021. vol. 35. no. 12. pp. 10790-10797.
110. Vu M.T., Beurton-Aimar M., Marchand S. Multitask multi-database emotion recognition // Proceedings of IEEE/CVF International Conference on Computer Vision. 2021. pp. 3637-3644.

111. Velichko A., Markitantov M., Kaya H., et al. Complex Paralinguistic Analysis of Speech: Predicting Gender, Emotions and Deception in a Hierarchical Framework // Proceedings of Interspeech. 2022. pp. 4735-4739.

Двойникова Анастасия Александровна — младший научный сотрудник, 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, sentiment-анализ, анализ аффективных состояний человека. Число научных публикаций — 10. dvoynikova.a@iias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Маркитантов Максим Викторович — младший научный сотрудник, лаборатория речевых и многомодальных интерфейсов, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: искусственный интеллект, машинное обучение, речевые технологии, компьютерная паралингвистика, распознавание характеристик диктора, распознавание пола и возраста диктора, обнаружение защитных масок по аудиоинформации. Число научных публикаций — 11. m.markitantov@yandex.ru; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Рюмина Елена Витальевна — младший научный сотрудник, лаборатория речевых и многомодальных интерфейсов, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: аффективные вычисления, цифровая обработка изображений, распознавание аудиовизуальных сигналов, распознавание паралингвистических явлений, распознавание визуальной речи, машинное обучение, нейронные сети, биометрические системы, человеко-машинные интерфейсы. Число научных публикаций — 15. ryumina.e@iias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Уздяев Михаил Юрьевич — младший научный сотрудник, лаборатория технологий больших данных социокриберфизических систем, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: многомодальный анализ поведенческой активности пользователей, цифровая обработка изображений и видеосигнала, машинное обучение, нейронные сети, биометрические системы. Число научных публикаций — 20. uzdyayev.m@iias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Величко Алёна Николаевна — младший научный сотрудник, лаборатория речевых и многомодальных интерфейсов, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: машинное обучение, речевые технологии, компьютерная паралингвистика, определение деструктивных паралингвистических явлений в разговорной речи человека, определение депрессии по разговорной речи человека. Число научных публикаций — 12. velichko.a.n@mail.ru; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Рюмин Дмитрий Александрович — канд. техн. наук, старший научный сотрудник, лаборатория речевых и многомодальных интерфейсов, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: цифровая обработка изображений, распознавание образов,

автоматическое распознавание визуальной речи, многомодальные интерфейсы, машинное обучение, нейронные сети, биометрия, человеко-машинные интерфейсы. Число научных публикаций — 62. gyumin.d@ias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Ляксо Елена Евгеньевна — д-р биол. наук, профессор, профессор, кафедра высшей нервной деятельности и психофизиологии биологического ф-та, Санкт-Петербургский государственный университет; ведущий научный сотрудник, лаборатория речевых и многомодальных интерфейсов, СПб ФИЦ РАН. Область научных интересов: акустика речи, детская речь, психофизиология речи. Число научных публикаций — 298. lyakso@gmail.com; Университетская наб., 7-9, 199034, Санкт-Петербург, Россия; р.т.: +7(921)996-24-92.

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. karrov@ias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0421.

Поддержка исследований. Данное исследование выполнено при поддержке Российского научного фонда, проект № 22-11-00321.

A. DVOYNIKOVA, M. MARKITANTOV, E. RYUMINA, M. UZDIAEV,
A. VELICHKO, D. RYUMIN, E. LYAKSO, A. KARPOV
**ANALYSIS OF INFOWARE AND SOFTWARE FOR HUMAN
AFFECTIVE STATES RECOGNITION**

Dvoynikova A., Markitantov M., Ryumina E., Uzdiaev M., Velichko A., Ryumin D., Lyakso E., Karpov A. **Analysis of infoware and software for human affective states recognition.**

Abstract. The article presents an analytical review of research in the affective computing field. This research direction is a component of artificial intelligence, and it studies methods, algorithms and systems for analyzing human affective states during interactions with other people, computer systems or robots. In the field of data mining, the definition of affect means the manifestation of psychological reactions to an exciting event, which can occur both in the short and long term, and also have different intensity. The affects in this field are divided into 4 types: affective emotions, basic emotions, sentiment and affective disorders. The manifestation of affective states is reflected in verbal data and non-verbal characteristics of behavior: acoustic and linguistic characteristics of speech, facial expressions, gestures and postures of a person. The review provides a comparative analysis of the existing infoware for automatic recognition of a person's affective states on the example of emotions, sentiment, aggression and depression. The few Russian-language, affective databases are still significantly inferior in volume and quality compared to electronic resources in other world languages. Thus, there is a need to consider a wide range of additional approaches, methods and algorithms used in a limited amount of training and testing data, and set the task of developing new approaches to data augmentation, transferring model learning and adapting foreign-language resources. The article describes the methods of analyzing unimodal visual, acoustic and linguistic information, as well as multimodal approaches for the affective states recognition. A multimodal approach to the automatic affective states analysis makes it possible to increase the accuracy of recognition of the phenomena compared to single-modal solutions. The review notes the trend of modern research that neural network methods are gradually replacing classical deterministic methods through better quality of state recognition and fast processing of large amount of data. The article discusses the methods for affective states analysis. The advantage of multitasking hierarchical approaches is the ability to extract new types of knowledge, including the influence, correlation and interaction of several affective states on each other, which potentially leads to improved recognition quality. The potential requirements for the developed systems for affective states analysis and the main directions of further research are given.

Keywords: affective states, affective computing, emotions, sentiment, depression, aggression, databases, computer systems.

References

1. Picard R.W. Affective Computing for HCI. HCI (1). 1999. pp. 829-833.
2. Viliūnas V.K. Jemocii. Bol'shoj psihologičeskij slovar' [Emotions. Big psychological dictionary]. SPb.: Prime Eurosign. 2007. pp. 565-568. (In Russ.)
3. Krafft-Ebing R. Lehrbuch der Psychiatrie. Stuttgart: Ferdinand Enke. 1897. 698 p.
4. Il'in E.P. Jemocii i čuvstva [Emotions and feelings]. Piter. 2011. 782 p. (In Russ.).
5. Thostov A.Sh., Kolymba I.G. Jemocii i affekty: obshhpsihologičeskij i patologičeskij aspekty [Emotions and affects: general psychological and pathological aspects]. Psihologičeskij žurnal – Psychological journal. 1998. no 4. pp. 41-48. (In Russ.).

6. Enikolopov S.N. Ponjatje agressii v sovremennoj psihologii [The concept of aggression in modern psychology]. *Prikladnaja psihologija – Applied psychology*. 2001. no. 1. pp. 60-72. (In Russ.).
7. Verkholyak O.V., Karpov A.A. Glava “Avtomaticeskij analiz jemocional'no okrashennoj rechi” v monografii “Golosovoj portret rebenka s tipichnym i atipichnym razvitiem” [Chapter “Automatic analysis of emotionally coloured speech” in monography “Voice portrait of a child with typical and atypical development”]. E.E. Ljako, O.V. Frolova, S.V. Grechanyj, Ju.N. Matveev, O.V. Verkholyak, A.A. Karpov. SPb. Izdatel'sko-poligraficheskaja asociacija vysshih uchebnyh zavedenij [Publishing and Printing Association of Higher Educational Institutions]. 2020. 204 p. (In Russ.).
8. Dvoynikova A. A., Karpov A. A. Analytical review of approaches to Russian text sentiment recognition. *Informacionno-upravliaiushchie sistemy – Information and Control Systems*. 2020. no. 4. pp. 20–30. (In Russ.).
9. Velichko A., Karpov A. Analytical Review of Automatic Systems for Depression Detection by Speech. *Informatics and Automation*. 2021. no. 20. pp. 497-529. (In Russ.).
10. American Psychiatric Association. *Diagnostic and Statistical Manual of Mental Disorders (DSM-5)*. American Psychiatric Publishing, Arlington, VA. 2013.
11. Tzirakis P., Trigeorgis G., Nicolaou M.A., et al. End-to-end multimodal emotion recognition using deep neural networks. *IEEE Journal of Selected Topics in Signal Processing*. 2017. vol. 11. no. 8. pp. 1301-1309.
12. Dhall A., Goecke R., Gedeon T. Collecting large, richly annotated facial-expression databases from movies. *IEEE Multimedia*. 2012. vol. 19. no. 03. pp. 34-41.
13. Kossaifi J., Tzimiropoulos G., Todorovic S., et al. AFEW-VA database for valence and arousal estimation in-the-wild. *Image and Vision Computing*. 2017. vol. 65. pp. 23-36.
14. Kollias D., Zafeiriou S. Aff-wild2: Extending the aff-wild database for affect recognition. *arXiv preprint arXiv:1811.07770*. 2018.
15. Lien J.J., Kanade T., Cohn J.F., et al. Automated facial expression recognition based on FACS action units. *Proceedings of third IEEE international conference on automatic face and gesture recognition*. IEEE. 1998. pp. 390-395.
16. Busso C., Bulut M., Lee C.-C., et al. IEMOCAP: Interactive emotional dyadic motion capture database. *Language Resources and Evaluation*. 2008. vol. 42. no. 4. pp. 335-359.
17. Ringeval F., Sonderegger A., Sauer J., et al. Introducing the RECOLA multimodal corpus of remote collaborative and affective interactions. *Proceedings of the 2013 10th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG)*. IEEE. 2013. pp. 1-8.
18. Kossaifi J., Walecki R., Panagakis Y., et al. SEWA DB: A Rich Database for Audio-Visual Emotion and Sentiment Research in the Wild. *IEEE Transactions on Pattern Analysis & Machine Intelligence*. 2021. vol. 43. no. 03. pp. 1022-1040.
19. McKeown G., Valstar M.F., Cowie R., et al. The SEMAINE corpus of emotionally coloured character interactions. *Proceedings of the IEEE International Conference on Multimedia and Expo*. IEEE. 2010. pp. 1079-1084.
20. Perepelkina O., Kazimirova E., Konstantinova M. RAMAS: Russian multimodal corpus of dyadic interaction for affective computing. *Proceedings of the International Conference on Speech and Computer*. Springer, Cham. 2018. pp. 501-510.
21. Poria S., Hazarika D., Majumder N., et al. Meld: A multimodal multi-party dataset for emotion recognition in conversations. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. 2019. pp. 527-536.

22. Zadeh A.B., Liang P.P., Poria S., et al. Multimodal Language Analysis in the Wild: CMU-MOSEI Dataset and Interpretable Dynamic Fusion Graph. Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. 2018. pp. 2236-2246
23. Pérez-Rosas V., Mihalcea R., Morency L.P. Utterance-level multimodal sentiment analysis. Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics. vol. 1. 2013. pp. 973-982.
24. Zadeh A., Zellers R., Pincus E., et al. Multimodal Sentiment Intensity Analysis in Videos: Facial Gestures and Verbal Messages. *EEE Intelligent Systems*. 2016. vol. 31. no. 6. pp. 82-88.
25. Morency L.P., Mihalcea R., Doshi P. Towards multimodal sentiment analysis: Harvesting opinions from the web. Proceedings of the 13th International Conference on Multimodal Interfaces. 2011. pp. 169-176.
26. Yu W., Xu H., Meng F., et al. Ch-sims: A chinese multimodal sentiment analysis dataset with fine-grained annotation of modality. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020. pp. 3718-3727.
27. Lefter I., Rothkrantz L.J.M., Burghouts G., et al. Addressing multimodality in overt aggression detection. Proceedings of the International Conference on Text, Speech and Dialogue. Springer, Berlin, Heidelberg. 2011. pp. 25-32.
28. Lefter I., Burghouts G.J., Rothkrantz L.J.M. An audio-visual dataset of human-human interactions in stressful situations. *Journal on Multimodal User Interfaces*. 2014. vol. 8. no. 1. pp. 29-41.
29. Lefter I., Rothkrantz L.J.M. Multimodal cross-context recognition of negative interactions. Proceedings of the Seventh International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW). IEEE. 2017. pp. 56-61.
30. Lefter I., Jomker C.M., Tuenté S.K., et al. NAA: A multimodal database of negative affect and aggression. Proceedings of the Seventh International Conference on Affective Computing and Intelligent Interaction (ACII). IEEE. 2017. pp. 21-27.
31. Nieves E.B., Déniz-Suárez O., García G., et al. Violence detection in video using computer vision techniques. Proceedings of the International conference on Computer Analysis of Images and Patterns. Springer, Berlin, Heidelberg. 2011. pp. 332-339.
32. Perez M., Kot A.C., Rocha A. Detection of real-world fights in surveillance videos. Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE. 2019. pp. 2662-2666.
33. Cheng M., Cai K., Li M. Rwf-2000: An open large scale video database for violence detection. Proceedings of the 25th International Conference on Pattern Recognition (ICPR). IEEE. 2021. pp. 4183-4190.
34. Kumar R., Reganti A.N., Bhatia A., et al. Aggression-annotated corpus of hindi-english code-mixed data. arXiv preprint arXiv:1803.09402. 2018.
35. Bozyiğit A., Utku S., Nasibov E. Cyberbullying detection: Utilizing social media features. *Expert Systems with Applications*. 2021. vol. 179. p. 115001.
36. Gratch J., Artstein R., Lucas G., et al. The Distress Analysis Interview Corpus of Human and Computer Interviews. Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14). Reykjavik, Iceland. 2014. pp. 3123-3128.
37. Valstar M., Schuller B., Smith K., et al. AVEC 2013: the continuous audio/visual emotion and depression recognition challenge. Proceedings of the 3rd ACM International workshop on Audio/visual emotion challenge (AVEC'13). Association for Computing Machinery, New York, NY, USA. 2013. pp. 3-10.
38. Yang Y., Fairbairn C., Cohn J. Detecting depression severity from vocal prosody. *IEEE Transactions on Affective computing*. 2013. vol. 4. no. 2. pp. 142-150.

39. Alghowinem S., Goecke R., Wagner M., et al. From joyous to clinically depressed: Mood detection using spontaneous speech. Proceedings of FLAIRS Conference, G.M. Youngblood and P.M. McCarthy, Eds. AAAI Press. 2012. pp. 141–146.
40. Huang Z., Epps J., Joachim D., et al. Depression detection from short utterances via diverse smartphones in natural environmental conditions. Proceedings of Interspeech. 2018. pp. 3393–3397.
41. Ryumina E., Karpov A. Facial expression recognition using distance importance scores between facial landmarks. CEUR Workshop Proceedings. 2020, vol. 2744. pp. 1-10.
42. Axyonov, A., Ryumin, D., Kagirow, I. Method of Multi-Modal Video Analysis of Hand Movements for Automatic Recognition of Isolated Signs of Russian Sign Language. Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. 2021. vol. XLIV-2/W1-2021. pp. 7–13.
43. He K., Zhang X., Ren S., et al. Deep residual learning for image recognition. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. 2016. pp. 770–778.
44. Simonyan K., Zisserman A. Very deep convolutional networks for largescale image recognition. Proceedings of the 3rd International Conference on Learning Representations (ICLR). 2015. pp. 1–14.
45. Niu B., Gao Z., Guo B. Facial expression recognition with LBP and ORB features. Computational Intelligence and Neuroscience. 2021. vol. 2021.
46. Verma S., Wang J., Ge Zh., et al. Deep-HOSeq: Deep higher order sequence fusion for multimodal sentiment analysis. Proceedings of IEEE International Conference on Data Mining (ICDM). IEEE. 2020. pp. 561-570.
47. Eyben F., Wenginger, F., Gross, F., et al. Recent developments in opensmile, the munich open-source multimedia feature extractor. Proceedings of ACM International Conference on Multimedia. 2013. pp. 835–838.
48. Schuller B.W., Batliner A., Bergler C., et al. The INTERSPEECH 2021 Computational Paralinguistics Challenge: COVID-19 Cough, COVID-19 Speech, Escalation & Primitives. Proceedings of Interspeech. 2021. pp. 431–435.
49. Eyben F., Scherer K.R., Schuller, B.W., et al. The Geneva minimalistic acoustic parameter set (GeMAPS) for voice research and affective computing. IEEE Transactions on Affective Computing. 2015. vol. 7. no. 2. pp. 190–202.
50. Schmitt M., Ringeval F., Schuller B.W. At the border of acoustics and linguistics: Bag-of-Audio-Words for the recognition of emotions in speech. Proceedings of Interspeech. 2016. pp. 495–499.
51. Kaya H., Karpov A.A., Salah A.A. Fisher vectors with cascaded normalization for paralinguistic analysis. Proceedings of Interspeech. 2015. pp. 909–913.
52. Zhao Z., Zhao Y., Bao Z., et al. Deep spectrum feature representations for speech emotion recognition. Proceedings of Workshop on Affective Social Multimedia Computing and First Multi-Modal Affective Computing of Large-Scale Multimedia Data. 2018. pp. 27–33.
53. Freitag M., Amiriparian S., Pugachevskiy S., et al. AuDeep: Unsupervised learning of representations from audio with deep recurrent neural networks. The Journal of Machine Learning Research. 2017. vol. 18. no. 1. pp. 6340–6344.
54. Shor J., Jansen A., Maor R., et al. Towards Learning a Universal Non-Semantic Representation of Speech. Proceedings of Interspeech. 2020. pp. 140–144.
55. Wagner J., Triantafyllopoulos A., Wierstorf H., et al. Dawn of the transformer era in speech emotion recognition: closing the valence gap. arXiv preprint arXiv:2203.07378. 2022. pp. 1-25.

56. Degottex G., Kane J., Drugman T., et al. COVAREP – A collaborative voice analysis repository for speech technologies. Proceedings of International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2014. pp. 960-964.
57. Sogancioglu G., Verkholiyak O., Kaya H., et al. Is Everything Fine, Grandma? Acoustic and Linguistic Modeling for Robust Elderly Speech Emotion Recognition. Proceedings of Interspeech. 2020. pp. 2097-2101.
58. Sebastian J., Pierucci P. Fusion Techniques for Utterance-Level Emotion Recognition Combining Speech and Transcripts. Proceedings of Interspeech. 2019. pp. 51-55.
59. Xu H., Zhang H., Han K., et al. Learning alignment for multimodal emotion recognition from speech. arXiv preprint arXiv:1909.05645. 2019.
60. Dellaert F., Polzin T., Waibel A. Recognizing emotion in speech. Proceedings of the 4th Int. Conf. Spoken Lang. Process (ICSLP). 1996. pp. 1970-1973.
61. Neiberg D., Elenius K., Laskowski K. Emotion recognition in spontaneous speech using GMMs. Proceedings of the 9th Int. Conf. Spoken Lang. Process. 2006. pp. 809-812.
62. Nogueiras A., Moreno A., Bonafonte A., et al. Speech emotion recognition using hidden Markov models. Proceedings of the 7th Eur. Conf. Speech Commun. Technol. 2001. pp. 746-749.
63. Raudys Š. On the universality of the single-layer perceptron model. Neural Networks and Soft Computing. Physica. Heidelberg. 2003. pp. 79-86.
64. Wang J., Lu S., Wang S.-H., et al. A review on extreme learning machine. Multimedia Tools and Applications. 2021. pp. 1-50.
65. Kruse R., Borgelt C., Klawonn F., et al. Multi-layer perceptrons. Computational Intelligence. Springer, Cham. 2022. pp. 53-124.
66. Sainath T.N., Vinyals O., Senior A., et al. Convolutional, long short-term memory, fully connected deep neural networks. Proceedings of International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2015. pp. 4580-4584.
67. Kim J., Truong K.P., Englebienne G., et al. Learning spectro-temporal features with 3D CNNs for speech emotion recognition. Proceedings of the 7th International Conference on Affective Computing and Intelligent Interaction (ACII). 2017. pp. 383-388.
68. Chao L., Tao J., Yang M., et al. Long short term memory recurrent neural network based multimodal dimensional emotion recognition. Proceedings of the 5th International Workshop on Audio/Visual Emotion Challenge. 2015. pp. 65-72.
69. Wang J., Xue M., Culhane R., et al. Speech emotion recognition with dual-sequence lstm architecture. Proceedings of International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2020. pp. 6474-6478.
70. Chen Q., Huang, G. A novel dual attention-based blstm with hybrid features in speech emotion recognition. Engineering Applications of Artificial Intelligence. 2021. vol. 102. p. 104277.
71. Zhao J., Mao X., Chen L. Speech emotion recognition using deep 1d & 2d cnn lstm networks. Biomedical Signal Processing and Control. 2019. vol. 47. pp. 312-323.
72. Milner R., Jalal M.A., Ng R.W., et al. A cross-corpus study on speech emotion recognition. Proceedings of IEEE Automatic Speech Recognition and Understanding Workshop (ASRU). 2019. pp. 304-311.
73. Vaswani A., Shazeer N., Parmar N., et al. Attention is all you need. Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017). 2017. vol. 30. pp. 1-11.
74. Ho N.H., Yang H.J., Kim S.H., et al. Multimodal approach of speech emotion recognition using multi-level multi-head fusion attention-based recurrent neural network. IEEE Access. 2020. vol. 8. pp.61672-61686.

75. Hsu W.N., Bolte B., Tsai Y.-H.H., et al. Hubert: Self-supervised speech representation learning by masked prediction of hidden units. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*. 2021. vol. 29. pp. 3451–3460.
76. Siriwardhana S., Reis A., Weerasekera R., et al. Jointly fine-tuning “bert-like” self-supervised models to improve multimodal speech emotion recognition. *arXiv preprint arXiv:2008.06682*. 2020. pp. 1-5.
77. Kratzwald B., Ilic S., Kraus M., et al. Deep learning for affective computing: Text-based emotion recognition in decision support. *Decision Support Systems*. 2018. vol. 115. pp. 24–35.
78. Stappen L., Baird A., Christ L., et al. The muse 2021 multimodal sentiment analysis challenge: Sentiment, emotion, physiological-emotion, and stress. *Proceedings of the 29th ACM International Conference on Multimedia (ACM MM)*. 2021. pp. 5706–5707.
79. Dresvyanskiy D., Ryumina E., Kaya H., et al. 2022. End-to-End Modeling and Transfer Learning for Audiovisual Emotion Recognition in-the-Wild. *Multimodal Technologies and Interaction*. vol 6. no. 2. pp. 11.
80. Fedotov D., Kaya H., Karpov A. Context Modeling for Cross-Corpus Dimensional Acoustic Emotion Recognition: Challenges and Mixup. *Proceedings of the 20th International Conference on Speech and Computer (SPECOM-2018)*. 2018. pp. 155-165.
81. Wu C.H., Lin J.C., Wei W.L. Survey on audiovisual emotion recognition: databases, features, and data fusion strategies. *APSIPA Transactions on Signal and Information Processing*. 2014. vol. 3. pp. 18.
82. Al Osman H., Falk T.H. Multimodal affect recognition: Current approaches and challenges. *Emotion and Attention Recognition Based on Biological Signals and Images*. 2017. pp. 59-86.
83. Liu D., Wang Z., Wang L., et al. Multi-Modal Fusion Emotion Recognition Method of Speech Expression Based on Deep Learning. *Frontiers in Neurorobotics*. 2021. pp. 13.
84. Zhang C., Yang Z., He X., et al. Multimodal intelligence: Representation learning, information fusion, and applications. *IEEE Journal of Selected Topics in Signal Processing*. 2020. vol. 14. no. 3. pp. 478-493.
85. Markitantov M., Ryumina E., Ryumin D., et al. Biometric Russian Audio-Visual Extended MASKS (BRAVE-MASKS) Corpus: Multimodal Mask Type Recognition Task. *Proceedings of Interspeech*. 2022. pp. 1756-176.
86. Yang L., Sahli H., Xia X., et al. Hybrid depression classification and estimation from audio video and text information. *Proceedings of the 7th Annual Workshop on Audio/Visual Emotion Challenge (AVEC)*. 2017. pp. 45-51.
87. Mai S., Hu H., Xing S. Modality to modality translation: An adversarial representation learning and graph fusion network for multimodal fusion. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020. vol. 34. no. 01. pp. 164-172.
88. Ghosal D., Akhtar M.S., Chauhan D., et al. Contextual inter-modal attention for multimodal sentiment analysis. *Proceedings of the Conference on Empirical Methods in Natural Language Processing*. 2018. pp. 3454-3466.
89. Akhtar M.S., Chauhan D.S., Ghosal D., et al. Multi-task learning for multi-modal emotion recognition and sentiment analysis. *arXiv preprint arXiv:1905.05812*. 2019. pp. 1-10.
90. Sun Z., Sarma P, Sethares W., et al. Learning relationships between text, audio, and video via deep canonical correlation for multimodal language analysis. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020. vol. 34. no. 05. pp. 8992-8999.3.
91. Mai S., Hu H., Xing S. Divide, conquer and combine: Hierarchical feature fusion network with local and global perspectives for multimodal affective computing.

- Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019. pp. 481-492.
92. Chauhan D.S., Akhtar M.S., Ekbal A., et al. Context-aware interactive attention for multi-modal sentiment and emotion analysis. Proceedings of the Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). 2019. pp. 5647-5657.
 93. Delbrouck J.B., Tits N., Brousmiche M., et al. A transformer-based joint-encoding for emotion recognition and sentiment analysis. arXiv preprint arXiv:2006.15955. 2020.
 94. Khare A., Parthasarathy S., Sundaram S. Self-Supervised learning with cross-modal transformers for emotion recognition. IEEE Spoken Language Technology Workshop (SLT). IEEE. 2021. pp. 381-388.
 95. Zaib S., Asif M., Arooj M. Development of Aggression Detection Technique in Social Media. International Journal of Information Technology and Computer Science. 2019. vol. 5. no. 8. pp. 40-46.
 96. Levonevskij D.K., Savel'ev A.I. Podhod i arhitektura dlja sistematizacii i vyjavlenija priznakov agressii v russkojazychnom tekstovom kontente [Approach and architecture for systematization and identification of aggression signs in Russian-language text content.]. Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naja tehnika i informatika – Tomsk state university journal of control and computer science. Control, computer engineering and informatics. 2021. no. 54. pp. 56-64. (In Russ.).
 97. Sadiq S., Mehmood A., Ullah S., et al. Aggression detection through deep neural model on twitter. Future Generation Computer Systems. 2021. vol. 114. pp. 120-129.
 98. Tommasel A., Rodriguez J.M., Godoy D. Textual Aggression Detection through Deep Learning. TRAC@ COLING 2018. 2018. pp. 177-187.
 99. Mandl T., Modha S., Shahi G.K., et al. Overview of the hasoc subtrack at fire 2021: Hate speech and offensive content identification in english and indo-aryan languages. arXiv preprint arXiv:2112.09301. 2021.
 100. Potharaju Y., Kamsali M., Kesavari C.R. Classification of Ontological Violence Content Detection through Audio Features and Supervised Learning. International Journal of Intelligent Engineering and Systems. 2019. vol. 12. no. 3. pp. 20-30.
 101. Sahoo S., Routray A. Detecting aggression in voice using inverse filtered speech features. IEEE Transactions on Affective Computing. 2016. vol. 9. no. 2. pp. 217-226.
 102. Santos F., Durães D., Marcondes F.M., et al. In-car violence detection based on the audio signal. Proceedings of the International Conference on Intelligent Data Engineering and Automated Learning. Springer, Cham. 2021. pp. 437-445.
 103. Liang Q., Li Y., Chen B., et al. Violence behavior recognition of two-cascade temporal shift module with attention mechanism. Journal of Electronic Imaging. 2021. vol. 30. no. 4. pp. 043009.
 104. Uzdyayev M.Yu. Neural network model for multimodal recognition of human aggression. Bulletin KRASEC. Physical and Mathematical Sciences. 2020. vol. 33. no. 4. pp. 132-149. (In Russ.).
 105. Yao Y., Papakostas M., Burzo M., et al. MUSER: MULTimodal Stress detection using Emotion Recognition as an Auxiliary Task. Proceedings of Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT). 2021. pp. 2714-2725.
 106. Sangwan S., Chauhan D.S., Akhtar M., et al. December. Multi-task gated contextual cross-modal attention framework for sentiment and emotion analysis. Proceedings of International Conference on Neural Information Processing. 2019. pp. 662-669.
 107. Kollias D., Zafeiriou S. Expression, affect, action unit recognition: Aff-wild2, multi-task learning and arcfac. arXiv preprint arXiv:1910.04855. 2019. pp. 1-15.

108. Li Y., Zhao T., Kawahara T. Improved End-to-End Speech Emotion Recognition Using Self Attention Mechanism and Multitask Learning. Proceedings of Interspeech. 2019. pp. 2803-2807.
109. Yu W., Xu H., Yuan Z., et al. Learning modality-specific representations with self-supervised multi-task learning for multimodal sentiment analysis. Proceedings of the AAAI Conference on Artificial Intelligence. 2021. vol. 35. no. 12. pp. 10790-10797.
110. Vu M.T., Beurton-Aimar M., Marchand S. Multitask multi-database emotion recognition. Proceedings of IEEE/CVF International Conference on Computer Vision. 2021. pp. 3637-3644.
111. Velichko A., Markitantov M., Kaya H., et al. Complex Paralinguistic Analysis of Speech: Predicting Gender, Emotions and Deception in a Hierarchical Framework. Proceedings of Interspeech. 2022. pp. 4735-4739.

Dvoynikova Anastasia — Junior researcher, Laboratory of speech and multimodal interfaces, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: artificial intelligence, machine learning, neural networks, recognition of protective masks by audio information, sentiment analysis, human affective states analysis. The number of publications — 10. dvoynikova.a@ias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0421.

Markitantov Maxim — Junior researcher, Laboratory of speech and multimodal interfaces, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: artificial intelligence, machine learning, speech technologies, computational paralinguistics, recognition of the speaker's characteristics, speaker's age and gender recognition, detection of protective masks by audio information. The number of publications — 11. m.markitantov@yandex.ru; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0421.

Ryumina Elena — Junior researcher, Laboratory of speech and multimodal interfaces, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: affective computing, digital image processing, audio-visual signal recognition, recognition of paralinguistic phenomena, visual speech recognition, machine learning, neural networks, biometric systems, human-machine interfaces. The number of publications — 15. ryumina.e@ias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0421.

Uzdiaev Mikhail — Junior researcher, Laboratory of big data technologies in socio-cyberphysical systems, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: multimodal analysis of user behavior activity, digital image processing, digital video processing, machine learning, neural networks, biometric systems. The number of publications — 20. uzdyae.v.m@ias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0421.

Velichko Alena — Junior researcher, Laboratory of speech and multimodal interfaces, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: machine learning, speech technologies, computational paralinguistics, detection of destructive paralinguistic phenomena in colloquial speech, depression detection in colloquial speech. The number of publications — 12. velichko.a.n@mail.ru; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0421.

Ryumin Dmitry — Ph.D., Senior researcher, Laboratory of speech and multimodal interfaces, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS).

Research interests: digital image processing, pattern recognition, automatic visual speech recognition, multimodal interfaces, machine learning, neural networks, biometrics, human-machine interfaces. The number of publications — 62. ryumin.d@iiias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0421.

Lyakso Elena — Ph.D., Dr.Sci., Professor, Professor, Department of higher nervous activity and psychophysiology, biology faculty, St. Petersburg State University; Leading researcher, Laboratory of speech and multimodal interfaces, SPC RAS. Research interests: speech acoustic, child speech, speech psychophysiology. The number of publications — 298. lyakso@gmail.com; 7-9, University Emb., 199034, St. Petersburg, Russia; office phone: +7(921)996-24-92.

Karpov Alexey — Ph.D., Dr.Sci., Professor, Head of laboratory, Laboratory of speech and multimodal interfaces, 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@iiias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0421.

Acknowledgements. This research was supported by Russian Science Foundation (grant № 22-11-00321).

В.Ю. ОСИПОВ, С.В. КУЛЕШОВ, Д.И. МИЛОСЕРДОВ, А.А. ЗАЙЦЕВА,
А.Ю. АКСЕНОВ

РЕКУРРЕНТНЫЕ НЕЙРОННЫЕ СЕТИ С НЕПРЕРЫВНЫМ ОБУЧЕНИЕМ В ЗАДАЧАХ МНОГОФУНКЦИОНАЛЬНОЙ ОБРАБОТКИ НОВОСТНЫХ ПОТОКОВ

Осипов В.Ю., Кулешов С.В., Милосердов Д.И., Зайцева А.А., Аксенов А.Ю.
Рекуррентные нейронные сети с непрерывным обучением в задачах многофункциональной обработки новостных потоков.

Аннотация. Главной задачей использования нейронных сетей является оперативное и точное решение различных творческих задач, таких как анализ и синтез новостных потоков при сохранении непрерывности обучения. Результатом такой обработки могут быть дайджесты, новостные потоки, прошедшие фильтрацию, а также прогнозы событий, позволяющих обеспечивать проактивность в управленческих решениях. Известные методы обработки новостей нейронными сетями и реализующие их технические решения не в полной мере обеспечивают решение возникающих в этой области задач. Необходимо расширить их функциональные возможности, совершенствовать пространственно-временное связывание сигналов в рекуррентных нейронных сетях. При обработке новостных потоков одновременно с непрерывным обучением рекуррентных нейронных сетей следует осуществлять селекцию, распознавание, восстановление, прогнозирование и синтез новостей. Для снижения остроты проблемы предлагается перспективный метод многофункциональной обработки новостных потоков с применением рекуррентных нейронных сетей с логической организацией слоев и непрерывным обучением. Метод основан на развитии ассоциативной обработки текстовой информации в потоковых рекуррентных нейронных сетях с управляемыми элементами. Ключевыми особенностями этого метода являются многофункциональная обработка информационных потоков с изменяющимися законами появления новостей. Метод предусматривает оперативный отбор, распознавание, восстановление, прогнозирование и синтез новостей на основе глубокой ассоциативной непрерывной обработки связей между текстовыми элементами. Реализующая предлагаемый метод нейросетевая система отличается от известных решений новыми элементами, связями между ними, а также выполняемыми функциями. По результатам экспериментов подтверждена расширенная функциональность метода. Выявлены новые особенности обработки новостных текстов потоковыми РНС. Предлагаемые решения могут найти применение при создании интеллектуальных систем нового поколения не только для обработки текстов, но и других видов информации.

Ключевые слова: рекуррентные нейронные сети, интеллектуальная обработка новостей, многофункциональность, непрерывность обучения.

1. Введение. Качественная и своевременная обработка новостных потоков, связанная с интерпретацией событий, может стать основой для построения прогнозов, построения автоматических систем поддержки принятия решений с проактивным управлением, и соответственно принятия важных управляющих решений, в том числе с серьезными экономическими последствиями. Такая обработка предполагает анализ больших потоков информации от различных

источников, которые могут содержать как истинные, так и ложные сообщения. Вручную выполнить такой анализ в сжатые сроки крайне затруднительно, что приводит к необходимости использования для обработки новостных потоков методов машинной интеллектуальной обработки. Выделяемые новости должны соответствовать следующим критериям качества: быть востребованы целевыми потребителями, обладать новизной (то есть не иметь дублирований с ранее обработанными) и релевантностью на текущий момент времени (соответствие новостей порождающим их информационным событиям), быть достоверными, полными и непротиворечивыми. Входной поток новостей должен подвергаться интеллектуальной обработке, обеспечивающей соответствие выделенным критериям. Результатом обработки могут быть дайджесты, новостные потоки, прошедшие фильтрацию, а также прогнозы событий, позволяющих обеспечивать проактивность в управленческих решениях. Для обработки больших потоков данных в целях получения качественных новостей применим ряд известных методов [1–5]. Для приведения различного вида данных к текстовой цифровой форме на выбранном языке применяют методы словесного описания изображений [6], системы машинного перевода [7]. При машинной обработке решаются задачи распознавания и классификации текстов и их фрагментов, определения тональности, тематической направленности [5, 8], при этом формируются тематические модели, отражающие структуру тематических коллекций. В основном эта обработка сводится к распознаванию и аннотированию текстов, формированию рефератов [9, 10]. При этом исходят из наиболее часто встречающихся слов и их сочетаний. Такой подход трудно применим для определения новизны сообщений, которые на начальном этапе жизни слабо выделяются по частоте встречаемости слов. Однако на его основе можно осуществлять прогнозы будущих тем [11, 12], а также различных общественных и экономических событий [13–16], связанных с ними. Прогнозирование содержания текстов при использовании тематических моделей сводится лишь к определению наборов слов без тесной связи между ними. Наиболее отработанными решениями выступают методы предсказания слов и окончаний в предложениях [17]. Среди общих недостатков решений на основе ассоциативно-вероятностного подхода к обработке текстов в части прогнозирования, селекции и анализа новостей можно выделить:

- необходимость учета широкого контекста;

- существенно ограниченная точность по обнаружению новых по содержанию сообщений, их классификации и прогнозированию при анализе малых объемов текста;
- слабый учет содержания обрабатываемых слов и связей между ними в текстах;
- невысокая интеллектуальность выделения и анализа новостей в потоках, по сравнению с ручной обработкой;
- значительная вычислительная сложность решаемых задач.

Наиболее перспективным направлением для совершенствования машинной обработки новостных потоков выступает разработка и применение новых интеллектуальных нейросетевых систем. Чем больше творческих задач могут решать такие системы, тем выше их уровень интеллектуальности.

Нейронные сети (НС) позволяют успешно связывать и запоминать элементы текстов на различных уровнях иерархии. Посредством этого в нейронных сетях формируются постоянно обновляемые пространственно-временные модели воспринимаемых сигналов, несущих информацию о текстах. Потенциально эти модели применимы для решения различных задач, связанных с обнаружением, распознаванием, прогнозированием и генерацией новостей. Целесообразно, чтобы эти задачи решались на одной и той же нейросетевой системе без прерывания ее обучения. Известен ряд работ по традиционной нейросетевой обработке новостных потоков [18–22] и другие.

В подобных задачах применяют как НС сети прямого распространения, так и рекуррентные нейронные сети (РНС). Успешность обработки нейронными сетями новостных потоков зависит не только от характеристик применяемых сетей, но и от совершенства кодирования текстов и декодирования результатов на выходе НС. В частности, для обработки текстов в импульсных НС они должны быть закодированы в виде последовательностей совокупностей единичных импульсов. Вид такого кодирования во многом может влиять на уровень обработки текстов, оперативность и точность получаемых результатов. Несомненно, показатели обработки текстов в НС сетях зависят от накопленного опыта, их структуры, размера, логической организации, реализуемых правил, обеспечивающих связывание, ассоциативное запоминание и извлечение сигналов из памяти сетей. Применение традиционных НС позволило совершенствовать интеллектуальную обработку новостных потоков. Однако это только в пределах решения задач классификации и распознавания текстов. Расширенными возможностями по

интеллектуальной обработке новостных потоков обладают потоковые рекуррентные нейронные сети (РНС). К их представителям следует отнести прежде всего GRU (Gated Recurrent Units) и LSTM (Long short-term memory) сети [23], а также потоковые РНС с управляемыми элементами [5, 24, 25]. Сети GRU и LSTM, хотя и обладают значительными возможностями по управлению своими параметрами, однако требуют обучения с учителем. При изменении законов поведения обрабатываемых новостных потоков эти сети необходимо переобучать. Этого недостатка лишены самообучающиеся потоковые РНС с управляемыми элементами [5, 24–27]. В отличие от широко известных РНС они могут быть наделены различными логическими структурами, и обладают возможностями по управлению ассоциативными взаимодействиями обрабатываемых сигналов в зависимости от текущих слоев. Однако свойства потоковых РНС, включая управление ассоциативным взаимодействием сигналов, во многом не исследованы. Открытыми остаются вопросы по решению на одних и тех же структурах потоковых РНС множества различных задач анализа и синтеза.

В настоящей статье развиваются взгляды на процессы управляемой обработки текстов в этих РНС применительно к селекции, распознаванию, восстановлению, прогнозированию и синтезу новостей при непрерывном обучении для различных классов информационных потоков.

Предлагается новый метод многофункциональной обработки новостей потоковыми РНС и реализующая его программная нейросетевая система, отличающаяся от известных решений функциями, составом элементов и связей между ними.

2. Метод. Известные функции обработки новостей потоковыми РНС [5] включают в себя: извлечение данных из потоков, фильтрацию данных, кодирование, нейросетевое выделение текущих и прогнозирование содержания возможных информационных событий. Представление входных данных основано на предобработке (нормализации) новостных текстов с использованием NLP-инструментария [28] с последующим формированием связей между основными лексическими единицами на основе синтаксических конструкций [29]. При этом идентификаторы распределяются на основе словарей, как предопределенных заранее, так и формируемых в процессе обработки. Сами слова при вводе в РНС представляются соотношенными в пространстве и времени наборами единичных импульсов. В состав нейросетевой системы, реализующей прототип предлагаемого метода, входят две одинаковые потоковые РНС, а

также блок управления сетями [5, 25]. Схема потоковой РНС включает в себя два слоя, связанные через единичные задержки управляемыми синапсами, а также собственный блок управления [24]. Эти РНС за счет реализуемых пространственных сдвигов сигналов при передаче от слоя к слою наделяются прозрачными логическими структурами. Сигналы при обработке за счет этих сдвигов продвигаются вдоль слоев. Предусмотрена возможность управления направленностью и параметрами расходимости единичных сигналов при передаче от слоя к слою. Однако не проработаны вопросы, как управлять ассоциативными взаимодействиями сигналов внутри сетей при селекции новостей, их распознавании, восстановлении, прогнозировании и генерации при сохранении непрерывного обучения. Кроме этого не совершенны правила управления самими РНС со стороны внешнего блока управления. Предлагается метод многофункциональной обработки новостей потоковыми РНС и реализующая его система, обеспечивающая преодоление этих недостатков.

Поясним предлагаемый метод на примере нейросетевой системы, реализующей его. Структура этой системы приведена на рисунке 1.

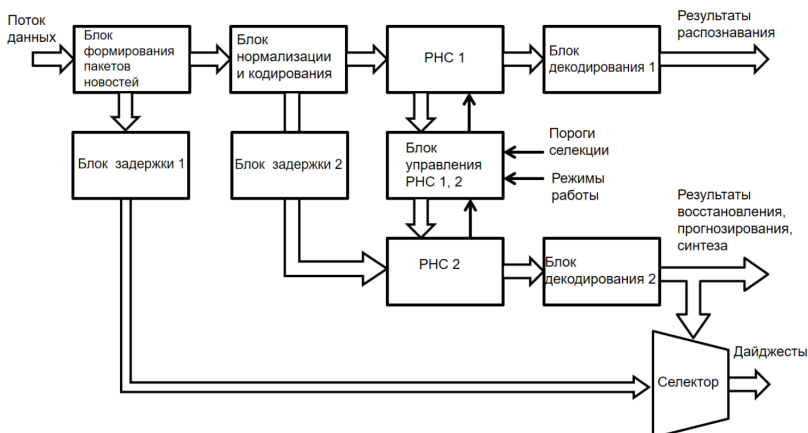


Рис. 1. Структура нейросетевой системы, реализующей метод

В этой системе используются две одинаковые импульсные потоковые РНС с блок-схемой, отраженной на рисунке 2.




Рис. 2. Блок-схема потоковой РНС с управляемыми элементами

Эти РНС наделяются одной и той же логической структурой. Пример одной из возможных логических структур этих РНС приведен на рисунке 3, где 1, 3 – направления продвижения совокупностей единичных импульсов (SSP) вдоль и между слоями; 2 – линии разделения слоев сети на логические поля за счет реализуемых пространственных сдвигов SSP при передаче от слоя к слою.




Рис. 3. Пример логической структуры потоковой РНС

Значение потенциала на выходе каждого i -го импульсного нейрона принимающего слоя РНС определяется как:

$$x_i(t) = \begin{cases} 1, \text{ если } \sum_{j=1}^N x_j(t) \cdot w_{ij}(t) \geq I_0; t_{i0} \geq T_R \\ 0, \text{ в других случаях} \end{cases}.$$

В этом выражении приняты обозначения:

$x_j(t)$ – значения выходных потенциалов нейронов передающего слоя РНС;

$w_{ij}(t)$ – веса синапсов, связывающие i -й принимающий нейрон с j -ми передающими нейронами;

N – число нейронов в каждом слое РНС;

I_0 – порог возбуждения нейрона;

t_{i0} – время, прошедшее после предыдущего возбуждения i -го нейрона;

T_R – время невосприимчивости нейронов после возбуждения.

Веса $w_{ij}(t)$ синапсов представляются в виде:

$$w_{ij}(t) = k_{ij}(t) \cdot \beta_{ij}(t) \cdot \eta_{ij}(t),$$

где $k_{ij}(t)$ – весовой коэффициент, $\eta_{ij}(t)$ – функция ослабления сходящихся единичных образов, $\beta_{ij}(t)$ – функция ослабления расходящихся единичных импульсов, передаваемых от j -х нейронов к i -м нейронам,

$$k_{ij}(t) = th(\gamma \cdot g_{ij}(t));$$

$$th(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}};$$

γ – коэффициент обучаемости;

$g_{ij}(t)$ – условное число импульсов, прошедших через ij -й синапс,

$$g_{ij}(t) = g_{ij}(t - \Delta t) \pm \Delta g_{ij}(t);$$

$\Delta g_{ij}(t)$ – приращение $g_{ij}(t)$. Это приращение положительное, когда возбуждающий импульс приходит на принимающий нейрон в состоянии ожидания;

$$\beta_{ij}(t) = 1 / (1 + \alpha_{ij} \cdot r_{ij}(t)),$$

$$r_{ij}(t) = ((\Delta x_{ij}(t) + n_{ij}(t)d)^2 + (\Delta y_{ij}(t) + m_{ij}(t)q)^2)^{1/2};$$

$$n_{ij}(t) = \pm 0, 1, \dots, D-1; m_{ij}(t) = \pm 0, 1, \dots, B-1;$$

где r_{ij} – удаленность связываемых через синапсы нейронов (расстояний между ними на плоскости X, Y). Полагается, что расстояние между взаимодействующими слоями нейронной сети стремится к нулю; $\Delta x_{ij}, \Delta y_{ij}$ – проекции связи j -го нейрона с i -м на оси X, Y без учета пространственных сдвигов; d, q – величины единичных сдвигов, соответственно, по координатам X, Y ; D, B – число, соответственно, столбцов и строк, на которые разбивается каждый слой нейронной сети за счет сдвигов; n_{ij}, m_{ij} – кратность единичных сдвигов при передаче импульсов от j -х нейронов к i -м нейронам. Произведение $d \times q$ определяет площадь рабочего поля каждого слоя сети. Эта площадь равна числу входящих в поле нейронов.

Стирание информации о единичных импульсах с синапсов осуществимо за счет частичного отражения единичных импульсов от слоев сети.

Варьируя значениями параметров α_{ij} (коэффициентами ослабления) можно существенно изменять направленность ассоциативного взаимодействия единичных импульсов в сети. В рассматриваемом случае значения α_{ij} изменяются так, чтобы усиливался вызов сигналов из памяти сети в интересующем направлении.

Принципиальное отличие структуры нейросетевой системы на рисунке 1 от известных решений [5, 25] состоит в том, что дополнительно используются временные задержки, селектор и вводятся новые связи между блоками, а также она наделяется новыми функциями, реализуемыми блоком управления сетями. Селектор предназначен для выделения из обрабатываемых пакетов новостей тех, которые обладают требуемой информационной новизной.

3.1. Реализуемые функции. В соответствии с рисунком 1 предлагаемый метод предусматривает формирование пакета новостей, требующих обработки. Каждый новостной текст перед вводом в первую потоковую рекуррентную нейронную сеть (РНС 1) кодируется последовательностью идентификаторов в соответствии с описанным выше методом, и преобразуется в последовательность совокупностей единичных импульсов (СЕИ). После подачи последовательности СЕИ в РНС 1 в ней формируется пространственно-временная модель входных сигналов с учетом ранее запомненной информации. Эта модель постоянно обновляется при обработке СЕИ. Одновременно с непрерывным обучением РНС 1 решается задача классификации текстов, за счет ассоциативного вызова из памяти сети известных атрибутов. Блок управления периодически считывает и анализирует информацию с РНС 1. При таком анализе он распознает типы состояний РНС 1. Выделяются пять состояний в зависимости от уровня и пространственных характеристик загрузки сети СЕИ: 1 – начальное состояние; 2 – равномерной редкой загрузки сети; 3 – полной загрузки; 4, 5 – при загрузке сети в области ее входа и выхода, соответственно. В зависимости от этих состояний или по внешним командам блок управления сетями запускает один из основных режимов работы РНС 2 и самой нейросетевой системы. Это следующие режимы: селекция, восстановление текста, прогнозирование содержания, синтез новостей. После обработки СЕИ в РНС 1, 2 результаты декодируются и преобразуются в текстовую форму. Рассмотрим особенности работы нейросетевой системы в этих режимах.

3.2. Непрерывное обучение и распознавание. При поступлении СЕИ в РНС 1 они продвигаются вдоль слоев сети с входа на выход. При таком продвижении между СЕИ в РНС 1 устанавливаются и запоминаются пространственно-временные связи через изменение весов синапсов. Также изменяются состояния импульсных нейронов РНС 1. В обобщенном виде в векторной форме и дискретном времени описание работы РНС 1 можно свести к выражениям (1) – (3):

$$\mathbf{W}_t = \varphi(\mathbf{W}_{t-1} \circ \mathbf{U}_{t-1}, \mathbf{X}_{t-1}, \mathbf{S}_{t-1}^a), \quad (1)$$

$$\mathbf{X}_t = \psi(\mathbf{W}_{t-1} \circ \mathbf{U}_{t-1}, \mathbf{X}_{t-1}, \mathbf{S}_{t-1}^a), \quad (2)$$

$$\mathbf{S}_t^b \subset \mathbf{X}_t, \quad (3)$$

где $\mathbf{W}_t, \mathbf{W}_{t-1}$ – вектора синапсов на моменты времени t и $t-1$; $\mathbf{X}_t, \mathbf{X}_{t-1}$ – вектора состояний нейронов; \mathbf{U}_{t-1} – управляющие воздействия; \circ – символ поэлементного умножения значений векторов; $\mathbf{S}_{t-1}^a, \mathbf{S}_t^b$ – состояния входа и выхода РНС 1.

Заметим, что каждый импульсный нейрон может находиться в одном из следующих состояний: ожидание, возбуждение, временная невосприимчивость. Под распознаванием РНС 1 новостных текстов в нашем случае понимается отнесение их известному классу. В непрерывно обучаемую РНС 1 наряду с текстом \mathbf{S}_{t-1}^{a1} можно подавать характеризующий его класс $\mathbf{S}_{t-1}^{a2}, \mathbf{S}_{t-1}^a = \mathbf{S}_{t-1}^{a1} \cup \mathbf{S}_{t-1}^{a2}$. При обработке текста с учетом накопленного опыта при отсутствии на входе информации о классе РНС 1 может ассоциативно вызывать его из памяти при соответствующем управляющем воздействии.

3.3. Нейросетевая селекция. Для перехода в этот режим работы нейросетевой системы помимо нахождения РНС 1 в состоянии полной загрузки должны выполняться условия (4) – (6):

$$W_{\Sigma}(t) - W_{\Sigma}(t - \Delta t) > \Delta W_0, \quad (4)$$

$$\Delta W_{\Sigma}(t) = \sum_{m=1}^2 \sum_{i=1}^N \sum_{j=1}^N \Delta w_{mij}(t), \quad (5)$$

$$\Delta w_{mij}(t) = w_{mij}(t) - w_{mij}(t - \Delta t). \quad (6)$$

Суммарный вес $W_{\Sigma}(t)$ синапсов РНС 1 на текущий момент времени t должен превысить аналогичный их вес $W_{\Sigma}(t-\Delta t)$ на момент $t-\Delta t$ на заданную величину ΔW_0 . Этот прирост определяется согласно (5), где m – номер слоя сети; N – число нейронов в каждом слое; $w_{mij}(t), w_{mij}(t-\Delta t)$ – значения весов отдельных синапсов на моменты времени t и $t-\Delta t$. При выполнении условия (4), соответствующего наличию новых элементов в обрабатываемом тексте, блок управления считывает приращения $\Delta w_{mij}(t)$ весов синапсов из РНС 1 в РНС 2 с умножением их на заданный коэффициент ζ . Если пренебречь задержкой на считывание, то весам $w_{mij}^*(t)$ синапсов РНС 2 присваиваются значения $\Delta w_{mij}(t) \cdot \zeta$. Затем через РНС 2 с заданным порогом возбуждения нейронов пропускается блок закодированного текста, вызвавшего отмеченный прирост суммарных весов синапсов. В данном случае РНС 2 реализует интеллектуальную фильтрацию сигналов. В результате на выходе РНС 2 формируются усеченные

СЕИ, несущие только информацию о новых элементах текста. Затем в селекторе выделяется конкретный блок в исходном тексте, как весомое новостное событие.

3.4. Нейросетевое восстановление. Восстановление новостных текстов реализуется в РНС 2 только после установления факта, что РНС 1 находится в состоянии загрузки сети в области ее входа. В этом случае блоком управления считывается в РНС 2 информация с РНС 1 о значениях весов синапсов и состояниях нейронов. Затем РНС 2 начинает функционировать в ускоренном времени (режим, при котором за один такт работы РНС 1 в РНС 2 реализуется K тактов, $K \gg 1$) с усилением ассоциативного вызова сигналов из памяти сети в направлении ее выхода.

С формальной точки зрения этот процесс можно представить в виде (7) – (8):

$$\{\mathbf{W}_t, \mathbf{X}_t\} \rightarrow \{\mathbf{W}_t^*, \mathbf{X}_t^*\} \rightarrow \{\mathbf{W}_t^{*U} = \mathbf{W}_t^* \circ \mathbf{U}_t^*, \mathbf{X}_t^*\}, \quad (7)$$

$$\mathbf{X}_t^* = \psi(\mathbf{W}_t^{*U}, \mathbf{X}_{t-1}^*), \quad \mathbf{S}_t^{*b} \subset \mathbf{X}_t^*. \quad (8)$$

В (7) – (8) \mathbf{U}_t^* – это вектор управления направленностью ассоциативного взаимодействия сигналов в РНС 2 при их восстановлении; \circ – символ поэлементного умножения значений векторов; звездочка при векторах синапсов и состояний нейронов означает, что они относятся к РНС 2; $\psi(\cdot)$ – функция переходов, звездочка при обозначении времени отражает его ускоренное течение. Усиление ассоциативного взаимодействия сигналов в этом режиме можно реализовывать как путем непосредственного изменения весов синапсов, так и за счет изменения функций ослабления расходящихся единичных импульсов, в зависимости от которых рассчитываются эти веса.

Заметим, что восстановление текстовых новостей в рассматриваемом случае сводится к решению обратной задачи анализа.

3.5. Нейросетевое прогнозирование. Получение содержания будущих информационных событий на основе анализа текущих событий осуществимо, прежде всего, когда РНС 1 находится в состоянии полной загрузки или частичной загрузки в области входа сети. Для прогнозирования при полной загрузке РНС 1 блоком управления, как в предыдущем режиме, считывается информация с этой сети в РНС 2 о значениях весов синапсов и состоянии нейронов.

Затем РНС 2 запускается в работу в ускоренном времени с усилением ассоциативного вызова сигналов, в отличие от предыдущего режима, в направлении входа сети. В результате сеть вызовет из своей памяти текущими СЕИ связанные сигналы, отражающие содержание будущих новостей. В этом случае прогнозирование сводится только к решению прямой задачи анализа текста. Когда предусматривается прогнозирование будущих новостей при нахождении РНС 1 в состоянии частичной загрузки в области входа сети, предлагается сначала восстанавливать последовательность СЕИ (решать задачу обратного анализа) в РНС 2, а затем реализовывать в ней задачу прямого анализа. Точность прогнозирования будущих новостей может оцениваться стандартными показателями: MAE (mean absolute error), MAPE (mean absolute percentage error), RMSE (root-mean square error).

3.6. Нейросетевой синтез. Синтез новостей в РНС 2 осуществим, исходя из следующих условий. Первая РНС должна находиться в состоянии равномерной, но редкой загрузки сети совокупностями единичных импульсов, несущими информацию об обрабатываемых текстах. Также из РНС 1 в РНС 2 должна быть считана информация о значениях весов синапсов и состояниях нейронов. В этом случае РНС 2 должна быть запущена на исполнение в ускоренном режиме с равномерным ассоциативным вызовом сигналов из ассоциативной памяти. При таком вызове информации из памяти сети редкие СЕИ дополняются связанными с ними по содержанию сигналами и сформируется корректная последовательность слов, составляющая новость. В итоге посредством анализа состояний РНС 1 и управления ассоциативным вызовом сигналов из памяти РНС 2 реализуемы, как задачи нейросетевого синтеза, так прямая и обратная задачи анализа новостных текстов.

4. Результаты и обсуждение. Оценим возможности предложенного метода по решению на одной и той же структуре нейросетевой системы задач селекции, распознавания, восстановления, прогнозирования и синтеза новостей в виде текстов.

4.1. Исходные данные. Для проведения экспериментов был сформирован тестовый набор частично-упорядоченных по времени опубликования текстов новостей из русскоязычных новостных агрегаторов (с сайтов <http://finam.ru>, <http://rbc.ru>, <http://mail.ru> и статьи с сервиса <http://zen.yandex.ru>) без предварительной селекции по тематическим доменам. Они составили 300000 текстов без дублирования. Для подготовки датасетов осуществлялся полный сбор всех доступных страниц с ресурса с последующим анализом, фильтрацией и индексацией. Все собранные из открытых источников

документы преобразовывались из исходного формата (HTML, XML, DOC, PDF, ODT) в формат простого текста без разметки, служебных областей и рекламных материалов. Они нормализовались по форматированию (удалялись лишние служебные символы) и приводились к единой кодовой таблице UTF-8.

4.2. Особенности потоковых РНС. В первом варианте метод реализовывался программной нейросетевой системой, включающей две одинаковые потоковые двухслойные РНС со следующими характеристиками. Число нейронов в каждом слое РНС составляло 9600 единиц. Слои разбивались на логические поля с размером $60 \times 20 = 1200$ нейронов. Реализовывалась линейная схема продвижение СЕИ вдоль слоев сети. Во втором варианте применялись потоковые РНС с размерами слоев по 28800 нейронов. Каждый слой содержал восемь логических полей по 3600 нейронов. Сигналы в виде СЕИ продвигались вдоль слоев по спиральной схеме. В третьем варианте число нейронов в каждом слое РНС равнялось 1890 единиц. Слои разбивались на логические поля с размером 6×7 нейронов. Продвижение СЕИ вдоль слоев осуществлялось по петлевой схеме. Рассматривалось непосредственное кодирование слов перед вводом их в РНС и кодирование связей между ними.

4.3. Результаты селекции новостей. С использованием первого варианта нейросетевой системы, реализующей метод, проводилась серия из десяти экспериментов по обнаружению новизны обрабатываемых текстовых фрагментов по сравнению с уже обработанными новостями. В каждом эксперименте новостной поток состоял из двух тематических групп по 75 текстов. Общая длина последовательности составляла 150 текстов. Оценивались приросты суммарных весов синапсов при обработке таких последовательностей и ошибки обнаружения факта новизны обрабатываемого текста. Использовался пороговый обнаружитель. Результаты приведены на рисунках 4, 5 и в таблице 1.




Рис. 4. Изменение суммарных весов синапсов во времени при смене тематики обрабатываемых текстов




Рис. 5. Изменение суммарных весов синапсов при обработке текстов со смешанной тематикой

Таблица 1. Временные задержки (ΔT) и ошибки определения новизны при различных порогах обнаружения (Thr)

№ эксперимента	Thr $\times 1.8$		Thr $\times 2.0$		Thr $\times 2.2$	
	ΔT	Ошибка	ΔT	Ошибка	ΔT	Ошибка
1	5	0	7	0	-	1
2	-	1	-	1	-	1
3	2	0	3	0	3	0
4	0	0	1	0	1	0
5	5	0	5	0	-	1
6	2	0	2	0	2	0
7	5	0	8	0	9	0
8	0	0	0	0	0	0
9	2	0	2	0	2	0
10	2	0	2	0	2	0
Среднее	2.55	0.1	3.33	0.1	2.71	0.3

Установлено, что при смене тематической группы обрабатываемых текстов резко скачкообразно изменяется суммарный вес синапсов РНС (рисунок 4). Согласно рисунку 4 смена тематики текста произошла на 75 такте работы РНС, а всплеск суммарного веса синапсов проявился на 78 такте. В случаях перемешивания тематик в текстах таких резких скачков не наблюдается (рисунок 5). Он проявляется лишь при начальном вводе смешанного текста в РНС. Установлено, что возможности выявления факта новизны обрабатываемых текстов значительно зависят от принятого абсолютного или относительного порога ее обнаружения (таблица 1). В таблице 1 приведены ошибки второго рода – пропуска событий. С увеличением порога они растут. При понижении порога растут

ошибки первого рода – ложные срабатывания. Порог может задаваться на основе ранее накопленного опыта и требований к безошибочности выявления фактов новизны. За счет фильтрации во второй РНС текстов по новым связям и последующей селекции новых блоков текста в исходном новостном потоке удавалось формировать новостные дайджесты.

4.4. Результаты прогнозирования. С использованием второго варианта реализации нейросетевой системы, реализующей метод, проводились эксперименты по управляемому прогнозированию содержания, восстановлению и синтезу новостей. При этом оценивались возможности такого прогнозирования содержания новостей в зависимости от ширины кодирования связей между словами обрабатываемого текста (Таблица 2). Установлено, чем шире учет связей между словами, тем точнее результаты прогнозирования. Однако горизонт такого прогнозирования с приемлемой точностью из-за большого числа анализируемых событий и быстро меняющейся обстановки не велик. При горизонте прогнозирования равном 2 часам его точность в эксперименте 1 составляет 67.4 %, а при 4 часах - не превышает 53.8 %. В этих экспериментах период прогнозирования равнялся 2 часам. При периоде прогнозирования 30 мин. с горизонтом 2 часа ошибки могут не превышать 23 %. Для такой оценки использовались стандартные показатели MAE, MAPE, RMSE с учетом правил, отраженных в [5].

Таблица 2. Результаты прогнозирования содержания новостей

Индикатор	Эксперимент 1 с учетом широких связей		Эксперимент 2 с учетом только смежных связей	
	2 часа	4 часа	2 часа	4 часа
Среднее число связей	908.0	881.5	329.8	317.3
MAE	295.7	407.5	137.9	223.2
MAPE	32.6	46.2	41.8	70.4
RMSE	342.3	456.3	175.2	263.3

Также оценивались возможности прогнозирования новостных событий предлагаемым методом при высокоуровневом кодировании входных потоков. Для этого использовался третий вариант реализации нейросетевой системы с петлевой схемой продвижения СЕИ вдоль слоев. При этом каждое слово в новостном потоке кодировалось своим

единичным импульсом. В РНС 1 вводились последовательности непересекающихся СЕИ.

В частности, были обработаны последовательности закодированных слов “*Two roads diverged in a yellow wood, and sorry I could not travel both and be one traveler, long I stood and looked down one as far as I could to where it bent in the undergrowth*” из произведения “*The Road Not Taken*” Роберта Ли Фроста. Эти последовательности слов, закодированные соответствующими СЕИ, отражались на первом слое РНС 1, как показано на рисунке 6. Стрелками на рисунке 6 обозначены направления продвижения СЕИ вдоль слоев.




Рис. 6. Состояние первого слоя РНС 1 после введения в нее анализируемой закодированной последовательности слов

После однократного восприятия РНС 1 данных в нее вводился ограниченный набор “*Two roads diverged in a yellow wood, and sorry I could not travel both*” этих же закодированных слов. Затем информация о состоянии РНС 1 считывалась в РНС 2, и на ней путем ускоренного ассоциативного вызова сигналов из памяти осуществлялось прогнозирование последующих слов.

Пример состояния первого слоя RNN 2 перед таким вызовом показан на рисунке 7а. Результат этого вызова сигналов отражен на рисунке 7б. Он выделен штрихпунктирными линиями.




Рис. 7. Результаты прогнозирования закодированной последовательности слов: а) состояние первого слоя РНС 2 до ассоциативного вызова СЕИ из памяти; б) состояние этого слоя после такого вызова

По этому результату после расшифровки из памяти РНС 2 вызывалась полная последовательность. Состояние первого слоя РНС 2 на рисунке 7б отражает лишь часть такого вызова. Выделенный штрихпунктирными линиями прогноз на рисунке 7б соответствует словам *“be one traveler, long I stood”*. Установлено, что отсутствие не только пересечения между обрабатываемыми СЕИ, но и их повторений позволяет исключать ложные выбросы. Данные результаты соответствуют не ожидаемому прогнозированию информационных событий, а соответствуют предиктивному формированию последующих языковых единиц на основе выявленных РНС языковых особенностей.

4.5. Результаты синтеза и восстановления. В рамках исследования проводились эксперименты по управляемому восстановлению и синтезу новостей в рамках предложенного метода при втором варианте его реализации. В интересах оценки возможностей восстановления пропущенных элементов текста нейросетевой системой с накопленным опытом в нее вводились усеченные совокупности связей между словами. Путем наблюдения за состояниями слоев РНС 2 оценивались устраненные пропуски этих связей. Напомним, каждая связь между словами, кодируется соотношенным в пространстве и времени единичным импульсом. Восстановление каждой такой связи дает эффект, равный извлечению из ассоциативной памяти сети сразу двух связанных слов. Результаты исследования показали, что уровень восстановления закодированных связей сильно зависит от числа активированных нейронов РНС и

значений весов синапсов с учетом реализуемого их усиления. В ограниченных размерах слоев РНС отношение числа восстанавливаемых связей по отношению к числу связей в неискаженном варианте в экспериментах составило 0.4. Заметим, что слишком сильное усиление ассоциативного вызова сигналов из памяти в направлении входа РНС при большом числе уже активированных нейронов может приводить к ложным вызовам. С учетом этого уровень усиления ассоциативного вызова сигналов из памяти должен согласовываться с уровнем активизации РНС. Примерно такие же оценки возможностей РНС по синтезу новостей были получены, как и при восстановлении. Однако наблюдалась одна особенность. Если при нейросетевом восстановлении новостей энергия активных нейронов направлялась в локализованное пространство, то при синтезе она распределялась во всем пространстве принимающих слоев РНС. В этом случае к усилению ассоциативного вызова сигналов из памяти РНС должны предъявляться другие требования.

5. Заключение. В результате выполненного исследования разработан метод многофункциональной обработки новостей потоковыми рекуррентными нейронными сетями с непрерывным обучением. Предложена реализующая его нейросетевая система.

Установлены новые закономерности в поведении этих сетей при ассоциативной обработке новостей, в том числе проявление фактов новизны в сообщениях через изменения суммарных весов синапсов в РНС. Разработанный метод в отличие от известных подходов обладает расширенными функциональными возможностями по решению различных задач анализа и синтеза новостных текстов при непрерывном обучении. Творческие задачи селекции, распознавания, восстановления, прогнозирования и синтеза новостей могут решаться на РНС с одной и той же структурой. Это достигается за счет развития правил ассоциативного взаимодействия сигналов в РНС и управления самими нейронными сетями. Для решения каждой из этих задач не требуется разрабатывать свою нейросетевую систему. Предложен критерий новизны текстов, обрабатываемых в РНС. Реализующая предлагаемый метод нейросетевая система отличается от известных решений новыми элементами, связями между ними, а также выполняемыми функциями. Используемые в ее составе потоковые рекуррентные нейронные сети с управляемыми элементами в отличие от сети GRU и LSTM не требуют обучения с учителем. По результатам экспериментов подтверждена расширенная функциональность метода. Выявлены новые особенности обработки новостных текстов потоковыми РНС. Отражено влияние на

показатели такой обработки как текущих параметров сетей, так и различных вариантов кодирования элементов текста при вводе в РНС. Предлагаемые решения могут найти применение при создании интеллектуальных систем нового поколения не только для обработки текстов, но и других видов информации.

Литература

1. Wu. Y. Language independent web news extraction system based on text detection framework. *Information Sciences*. 2016. vol. 342. pp.132-149.
2. Kaur G., Bajaj K. News Classification and Its Techniques: A Review. *IOSR Journal of Computer Engineering*. 2016. vol. 18. no. 1. pp. 22-26.
3. Zhang H., Boons F., Riza B.-N. Whose story is it anyway? Automatic extraction of accounts from news articles. *Information Processing & Management*. 2019. vol. 56 . no. 5. pp. 1837-1848.
4. Papagiannopoulou E., Tsoumakas G. Local word vectors guiding keyphrase extraction. *Information Processing & Management*. 2018. vol. 54. no. 6. pp. 888-902.
5. Osipov V., Kuleshov S., Zaytseva A., Levonevskiy D., Miloserdov D. Neural network forecasting of news feeds. *Expert systems with applications*. 2021. vol. 169. p. 114521.
6. Ji Z., Chen K., Wang H. Step-Wise Hierarchical Alignment Network for Image-Text Matching. *Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence (IJCAAI-2021)*. pp. 765- 771.
7. Rivera-Trigueros I. Machine translation systems and quality assessment: a systematic review. *Language Resources & Evaluation* 10 April, 2021.
8. Chaudhary and Bali. EASTER: Simplifying Text Recognition using only 1D Convolutions. *The 34th Canadian Conference on Artificial Intelligence, Vancouver, 2021*.
9. Grosman J., Furtado P., Rodrigues A., Schardong G., Barbosa S., Lopes H. Eras: Improving the quality control in the annotation process for natural language processing tasks. *Information Systems*. 2020. vol. 93. p. 101553.
10. Ashari A., Riasetiawan M. Document summarization using TextRank and semantic network. *International journal intelligent systems and applications*. 2017. vol. 1. pp. 26-33.
11. Mele I., Bahrainian S., Crestani F. Event mining and timeliness analysis from heterogeneous news streams. *Information Processing and Management*. 2019. vol. 56. pp. 969–993.
12. Curiskis S., Drake B., Osborn T., Kennedy P. An evaluation of document clustering and topic modelling in two online social networks: Twitter and Reddit. *Information Processing & Management*. 2019. p. 102034.
13. Rezaeinia S., Rahmani R., Ghodsi A., Veisi H. Sentiment Analysis Based on Improved Pre-Trained Word Embeddings. *Expert Systems with Applications*. 2019. vol. 117, pp. 139-147.
14. Hemmatian F., Sohrabi M. A survey on classification techniques for opinion mining and sentiment analysis. *Artificial Intelligence Review*. 2019. vol. 52. pp. 1495–1545.
15. Li J., Chen W., Gu B., Fang J., Li Z., Zhao L. Measuring semantic relatedness with knowledge association network. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2019. vol. LNCS 11446. pp. 676-691.

16. Ardia D., Bluteau K., Boudt K. Questioning the news about economic growth: Sparse forecasting using thousands of newsbased sentiment values. *International Journal of Forecasting*. 2019. vol. 35 (4). pp. 1370 – 1386.
17. Sutskever I., Martens J., Hinton G. Generating Text with Recurrent Neural Networks. *Proceedings of the 28th International Conference on Machine Learning, ICML 2011, Bellevue, Washington, USA, 2011*. pp. 1017-1024.
18. Widodo A., Naomi N., Purnomo F. Prediction of Research Topics Using Combination of Machine Learning and Logistic Curve. *Journal of Theoretical and Applied Information Technology*. 2013. vol. 49 (3). pp. 725 – 732.
19. Cabana A., Mizraji E., Valle-Lisboa J. A neural model that implements probabilistic topics. *Neurocomputing*. 2016. vol. 171. pp. 1099-1107.
20. Wang R., Zhou D., He Y. ATM: Adversarial-neural Topic Model. *Information Processing & Management*. 2019. vol. 56(6). p. 102098.
21. Wei Wei, Guo C. A text semantic topic discovery method based on the conditional co-occurrence degree. *Neurocomputing*. 2019. vol. 368. pp. 11 – 24.
22. Mukhina K., Visheratin A., Nasonov D. Urban events prediction via convolutional neural networks and Instagram data. *Procedia Computer Science*. 2019. vol. 156. pp. 176-184.
23. Recurrent Neural Network Tutorial (2015), Part 4 – Implementing a GRU/LSTM RNN with Python and Theano – WildML. <https://dennybritz.com/posts/wildml/recurrent-neural-networks-tutorial-part-4/>.
24. Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*. 2018. vol. 308. pp. 194–204.
25. Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*. 2020. vol. 32. pp. 14885-14897.
26. Осипов В.Ю. Ассоциативная интеллектуальная машина. Информационные технологии и вычислительные системы. 2010. № 2. С. 59 – 67.
27. Osipov V., Zhukova N., Subbotin A., Glebovskiy P., Evnevich E. Intelligent escalator passenger safety management. *Scientific reports*. 2022. vol. 12. pp. 5506.
28. Zhang J. El-Gohary N.M. Semantic NLP-based information extraction from construction regulatory documents for automated compliance checking. *Journal of Computing in Civil Engineering*. 2016. vol. 30(2). pp. 1–14. doi: 10.1061/(ASCE)CP.1943-5487.0000346.
29. Kuleshov S., Zaytseva A., Aksenov A. Natural Language Search and Associative-Ontology Matching Algorithms Based on Graph Representation of Texts. In: Silhavy, R., Silhavy, P., Prokopova, Z. (eds) *Intelligent Systems Applications in Software Engineering*. *Advances in Intelligent Systems and Computing*. Springer, Cham, 2019. vol 1046. pp. 285–294. doi 10.1007/978-3-030-30329-7_26.

Осипов Василий Юрьевич — д-р техн. наук, профессор, директор, Санкт-Петербургский институт информатики и автоматизации Российской академии наук, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук. Область научных интересов: математическое моделирование, интеллектуальные системы, нейронные сети, информационная безопасность. Число научных публикаций — 170. osipov_vasilyu@mail.ru; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812) 328-0887.

Кулешов Сергей Викторович — д-р техн. наук, профессор РАН, главный научный сотрудник, лаборатория автоматизации научных исследований, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук. Область научных интересов: ассоциативно-онтологический подход к анализу интернет-контента,

цифровые программно-определяемые инфокоммуникационные системы, обработка изображений и видеоданных, сжатие данных, обработка текстов, поисковые системы. Число научных публикаций — 140. kuleshov@iiias.spb.su; 14 линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812) 323-5139.

Милосердов Дмитрий Игоревич — руководитель группы, центр системного анализа и моделирования АО НТЦ РЭБ. Область научных интересов: нейронные сети, моделирование, обработка потоков данных, прогнозирование. Число научных публикаций — 12. dmmil94@yandex.ru; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-0887.

Зайцева Александра Алексеевна — канд. техн. наук, старший научный сотрудник, лаборатория автоматизации научных исследований, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук. Область научных интересов: методы и технологии обработки больших данных, обработка текстов, поисковые системы. Число научных публикаций — 98. cher@iiias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)323-5139.

Аксенов Алексей Юрьевич — канд. техн. наук, старший научный сотрудник, лаборатория автоматизации научных исследований, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук. Область научных интересов: цифровая обработка сигналов, методы обработки и компрессии 3D-данных, в том числе полученных с помощью 3D-сканеров, поисковые системы. Число научных публикаций — 51. a_aksenov@iiias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)323-5139.

Поддержка исследований. Работа выполнена при финансовой поддержке АНО «Аналитический центр при Правительстве Российской Федерации» (ИГК 000000D730321P5Q0002), соглашение № 70-2021-00141, а также бюджетной темы № FFZF-2022-0005.

V. OSIPOV, S. KULESHOV, D. MILOSERDOV, A. ZAYTSEVA, A. AKSENOV
**RECURRENT NEURAL NETWORKS WITH CONTINUOUS
LEARNING IN PROBLEMS OF NEWS STREAMS
MULTIFUNCTIONAL PROCESSING**

Osipov V., Kuleshov S., Miloserdov D., Zaytseva A., Aksenov A. **Recurrent Neural Networks with Continuous Learning in Problems of News Streams Multifunctional Processing.**

Abstract. The main task of using neural networks is the prompt and accurate solution of various creative tasks, including the analysis and synthesis of news flows, while maintaining the continuity of learning. The result of such processing can be digests, filtered news streams, as well as event forecasts that allow for proactivity in management decisions. Known methods of news processing by neural networks and technical solutions that implement them do not fully provide a solution to the problems that arise in this area. It is necessary to expand their functionality, and improve the space-time signal binding in recurrent neural networks. When processing news flows, simultaneously with continuous training of recurrent neural networks, selection, recognition, restoration, prediction and synthesis of news should be carried out. To reduce the severity of the problem, a promising method of multifunctional processing of news flows is proposed using recurrent neural networks with a logical organization of layers and continuous learning. The method is based on the development of associative processing of textual information in streaming recurrent neural networks with controlled elements. The key features of this method are the multifunctional processing of information flows with changing laws of news appearance. The method provides for operational selection, recognition, restoration, forecasting and synthesis of news based on deep associative continuous processing of links between text elements. The neural network system that implements the proposed method differs from the known solutions by new elements, connections between them, as well as by the functions performed. The results of the experiments confirmed the extended functionality of the method. New features of processing news texts by streaming RNNs are revealed. The proposed solutions can be used to create a new generation of intelligent systems not only for word processing but also for other types of information.

Keywords: recurrent neural networks, intelligent news processing, multifunctionality, continuity of learning.

References

1. Wu. Y. Language independent web news extraction system based on text detection framework. *Information Sciences*. 2016. vol. 342. pp. 132-149.
2. Kaur G., Bajaj K. News Classification and Its Techniques: A Review. *IOSR Journal of Computer Engineering*. 2016. vol. 18. no. 1. pp. 22-26.
3. Zhang H., Boons F., Riza Batis-ta-Navarro. Whose story is it anyway? Automatic extraction of accounts from news articles. *Information Processing & Management*. 2019. vol. 56. no. 5. pp. 1837-1848.
4. Papagiannopoulou E., Tsoumakas G. Local word vectors guiding keyphrase extraction. *Information Processing & Management*. 2018. vol. 54. no. 6. pp. 888-902.
5. Osipov V., Kuleshov S., Zaytseva A., Levonevskiy D., Miloserdov D. Neural network forecasting of news feeds. *Expert systems with applications*. 2021. vol. 169. p. 114521.
6. Ji Z., Chen K., Wang H. Step-Wise Hierarchical Alignment Network for Image-Text Matching. *Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence (IJCAI-2021)*. pp. 765- 771.

7. Rivera-Trigueros I. Machine translation systems and quality assessment: a systematic review. *Language Resources & Evaluation*, 10 April, 2021.
8. Chaudhary and Bali. EASTER: Simplifying Text Recognition using only 1D Convolutions. *The 34th Canadian Conference on Artificial Intelligence*, Vancouver, 2021.
9. Grosman J., Furtado P., Rodrigues A., Schardong G., Barbosa S., Lopes H. Eras: Improving the quality control in the annotation process for natural language processing tasks. *Information Systems*. 2020. vol. 93. p. 101553.
10. Ashari A., Riaseitawan M. Document summarization using TextRank and semantic network. *International journal intelligent systems and applications*. 2017. vol. 1. pp. 26-33.
11. Mele I., Bahrainian S., Crestani F. Event mining and timeliness analysis from heterogeneous news streams. *Information Processing and Management*. 2019. vol. 56. pp. 969–993.
12. Curiskis S., Drake B., Osborn T., Kennedy P. An evaluation of document clustering and topic modelling in two online social networks: Twitter and Reddit. *Information Processing & Management*. 2019. pp. 102034.
13. Rezaeinia S., Rahmani R., Ghodsi A., Veisi H. Sentiment Analysis Based on Improved Pre-Trained Word Embeddings. *Expert Systems with Applications*. 2019. vol. 117. pp. 139-147.
14. Hemmatian F., Sohrabi M. A survey on classification techniques for opinion mining and sentiment analysis. *Artificial Intelligence Review*. 2019. vol. 52. pp. 1495–1545.
15. Li J., Chen W., Gu B., Fang J., Li Z., Zhao L. Measuring semantic relatedness with knowledge association network. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2019. vol. LNCS 11446. pp. 676-691.
16. Ardia D., Bluteau K., Boudt K. Questioning the news about economic growth: Sparse forecasting using thousands of newsbased sentiment values. *International Journal of Forecasting*. 2019. vol. 35(4). pp.1370 – 1386.
17. Sutskever I., Martens J., Hinton G. Generating Text with Recurrent Neural Networks. *Proceedings of the 28th International Conference on Machine Learning, ICML 2011, Bellevue, Washington, USA, 2011*. pp. 1017-1024.
18. Widodo A., Naomi N., Purnomo F. Prediction of Research Topics Using Combination of Machine Learning and Logistic Curve. *Journal of Theoretical and Applied Information Technology*. 2013. vol. 49. no. 3. pp. 725 – 732.
19. Cabana A., Mizraji E., Valle-Lisboa J. A neural model that implements probabilistic topics. *Neurocomputing*. 2016. vol. 171. pp. 1099-1107.
20. Wang R., Zhou D., He Y. ATM: Adversarial-neural Topic Model. *Information Processing & Management*. 2019. vol. 56(6). p. 102098.
21. Wei Wei, Guo C. A text semantic topic discovery method based on the conditional co-occurrence degree. *Neurocomputing*. 2019. vol. 368. pp. 11 – 24.
22. Mukhina K., Visheratin A., Nasonov D. Urban events prediction via convolutional neural networks and Instagram data. *Procedia Computer Science*. 2019. vol. 156. pp. 176-184.
23. *Recurrent Neural Network Tutorial (2015), Part 4 – Implementing a GRU/LSTM RNN with Python and Theano – WildML*. Available at: <https://dennybritz.com/posts/wildml/recurrent-neural-networks-tutorial-part-4/>. (accessed 27.10.2022).
24. Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*. 2018. vol. 308. pp. 194–204.

25. Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*. 2020. vol. 32. pp. 14885-14897.
26. Osipov V.Yu. *Associativnaya intellektual'naya mashina. Informacionnye tekhnologii i vychislitel'nye sistemy*. 2010. no. 2. pp. 59 – 67.
27. Osipov V., Zhukova N., Subbotin A., Glebovskiy P., Evnevich E. Intelligent escalator passenger safety management. *Scientific reports*. 2022. vol. 12. p. 5506.
28. Zhang J. El-Gohary N.M. Semantic NLP-based information extraction from construction regulatory documents for automated compliance checking. *Journal of Computing in Civil Engineering*. 2016. vol. 30. no. 2. pp. 1–14. doi: 10.1061/(ASCE)CP.1943-5487.0000346.
29. Kuleshov S., Zaytseva A., Aksenov A. Natural Language Search and Associative-Ontology Matching Algorithms Based on Graph Representation of Texts. In: Silhavy, R., Silhavy, P., Prokopova, Z. (eds) *Intelligent Systems Applications in Software Engineering. Advances in Intelligent Systems and Computing*. Springer, Cham, 2019. vol. 1046. pp. 285–294. doi 10.1007/978-3-030-30329-7_26.

Osipov Vasily — Ph.D., Dr.Sci., Professor, Director, St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences, St. Petersburg Federal Research Center of the Russian Academy of Sciences. Research interests: mathematical modeling, intelligent systems, neural networks, information security. The number of publications — 170. osipov_vasily@mail.ru; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812) 328-0887.

Kuleshov Sergey — Ph.D., Dr.Sci., Professor of the RAS, Chief researcher, Laboratory of research automation, St. Petersburg Federal Research Center of the Russian Academy of Sciences. Research interests: associative-ontological approach to the analysis of Internet content, digital software-defined infocommunication systems, image and video data processing, data compression, text processing, search engines. The number of publications — 140. kuleshov@iias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812) 323-5139.

Miloserdov Dmitry — Head of the group, Center for system analysis and modeling JSC STC EW. Research interests: neural networks, modeling, data flow processing, forecasting. The number of publications — 12. dmmil94@yandex.ru; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-0887.

Zaytseva Alexandra — Ph.D., Senior researcher, Laboratory of research automation, St. Petersburg Federal Research Center of the Russian Academy of Sciences. Research interests: methods and technologies for processing big data, word processing, search engines. The number of publications — 98. cher@iias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(921)318-0136.

Aksenov Alexey — Ph.D., Senior researcher, Laboratory of research automation, St. Petersburg Federal Research Center of the Russian Academy of Sciences. Research interests: digital signal processing, methods of processing and compression of 3D data, including, search engines. The number of publications — 51. a_aksenov@iias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)323-5139.

Acknowledgements. This work was supported by the Analytical Center for the Government of the Russian Federation (IGK 000000D730321P5Q0002), agreement No. 70-2021-00141, and by the Budget № FFZF-2022-0005.

Р.Х. ЗУЛКАРНЕЕВ, Н.И. ЮСУПОВА, О.Н. СМЕТАНИНА, М.М. ГАЯНОВА,
А.М. ВУЛЬФИН

МЕТОДЫ И МОДЕЛИ ИЗВЛЕЧЕНИЯ ЗНАНИЙ ИЗ МЕДИЦИНСКИХ ДОКУМЕНТОВ

Зулкарнеев Р.Х., Юсупова Н.И., Сметанина О.Н., Гаянова М.М., Вульфин А.М. **Методы и модели извлечения знаний из медицинских документов.**

Аннотация. В работе выполнен анализ современного состояния проблемы извлечения знаний из клинических рекомендаций, представленных в виде слабоструктурированных корпусов текстовых документов на естественном языке с учетом их периодического обновления. Рассматриваемые методы интеллектуального анализа накопленных массивов медицинских данных позволяют автоматизировать ряд задач, направленных на повышение качества медицинской помощи за счет значимой поддержки принятия решений в процессе диагностики и лечения. Выполнен обзор известных публикаций, освещающий подходы к автоматизации построения нейросетевых языковых моделей, онтологий и графов знаний в задачах семантического моделирования проблемно-ориентированного корпуса текстов. Представлена структурно-функциональная организация системы извлечения знаний и автоматического построения онтологии и графа знаний проблемно-ориентированного корпуса для конкретной предметной области. Рассмотрены основные этапы извлечения знаний и динамического обновления графа знаний: извлечение именованных сущностей, семантическое аннотирование, извлечение терминов, ключевых слов, тематическое моделирование, идентификация тем и извлечение отношений. Формализованное представление текстов получено с помощью предобученной модели-трансформера BERT. Использовано автоматическое выделение триплетов «объект»-«действие»-«субъект» на основе частеречной разметки корпуса текстов для построения фрагментов графа знаний. Проведен эксперимент на корпусе медицинских текстов заданной тематики (162 документа обезличенных историй болезни пациентов педиатрического центра) без предварительной разметки с целью проверки предложенного решения по извлечению триплетов и конструирования на их основе графа знаний. Анализ экспериментальных результатов подтверждает необходимость более глубокой разметки корпуса текстовых документов для учета специфики медицинских текстовых документов. Показано, что модели общего назначения не позволяют приблизиться по качеству выделения именованных сущностей к специализированным моделям, однако, позволяют предварительно разметить корпус для дальнейшей верификации и уточнения разметки (оценка F1-меры для модели общего назначения – 20,4% по сравнению с вариантом использования словаря – 16,7%). Для неразмеченного корпуса текстов предложенное решение демонстрирует удовлетворительную работоспособность ввиду выделения атомарных фрагментов, включаемых в автоматически формируемую онтологию.

Ключевые слова: клинические тексты, извлечение информации, машинное обучение, интеллектуальный анализ медицинских данных, автоматическое построение онтологий, графы знаний.

1. Введение. Методы и системы интеллектуального анализа медицинских данных применяются для поддержки принятия решений в процессе диагностики заболеваний [1], контроля выполнения

лечебных протоколов и координации действий медицинского персонала, а также для предиктивного анализа и выявления на ранних этапах потенциально опасных состояний пациентов [2].

Медицинские данные можно условно разделить на две крупные категории [1]:

– структурированные данные, имеющие заранее определенный формат представления и хранения, хорошо поддающиеся формализации и последующей обработке с привлечением технологий интеллектуального анализа данных (результаты анализов и пр.);

– слабоструктурированные данные, представленные на естественном языке, со слабо выраженной или отсутствующей жесткой структурой (форматом) представления и хранения (анамнезы, протоколы осмотров, результаты обследований и так далее), для автоматизации анализа которых необходимо применение методов естественно-языковой обработки, формализации и извлечения структуры для последующего применения интеллектуального анализа и построения онтологии и графа знаний проблемной области.

Одним из актуальных направлений работы с данными, в том числе, с «большими данными» в медицинской практике является оперативный анализ (сбор, хранение, формализация, постоянное обновление, анализ, интерпретация) с целью создания регулярно пополняемых баз – клинических регистров. Высокая загруженность специалистов здравоохранения осложняет процесс принятия решений в сложных случаях, ввиду существенных временных затрат на поиск и анализ соответствующих источников. Методы интеллектуального анализа накопленных массивов медицинских данных позволяют автоматизировать подобные задачи, встречающиеся в клинической практике, повысив тем самым общий уровень качества медицинской помощи [1]. Внедрение интеллектуальных технологий направлено на повышение информационной осведомленности врача, помощь в быстром и обоснованном принятии клинического решения путем предоставления экспертных мнений и рекомендаций [3].

Ключевой проблемой при обработке и анализе медицинских данных является необходимость их формализации и извлечения знаний из периодически обновляемых клинических рекомендаций [4, 5]. Интеллектуальный анализ клинических текстов и извлечение знаний из накопленных массивов периодически меняющихся данных является одним из перспективных научных направлений на стыке компьютерной лингвистики, машинного обучения и медицины [6, 7], направленных на решение данной проблемы. На сегодняшний день

существует достаточно много технологий лингвистического анализа текстов [8], но, как показала практика, анализа текста на уровне только лингвистических правил недостаточно для корректного и полного извлечения фактов из корпуса медицинских документов [3]. Для эффективного извлечения фактов из текста база знаний должна содержать информацию, включающую медицинские онтологии, классификаторы, систематизированные знания в области анатомии, физиологии и патофизиологии человека. При сопровождении созданной базы знаний необходима постоянная актуализация информации с применением технологий анализа и сбора данных из первичных источников [9, 10, 11].

В работе [1] представлена комплексная система интеллектуальной обработки данных в многопрофильном педиатрическом центре, которая решает задачи автоматизации диагностики и выявления значимых признаков из накопленных слабоструктурированных данных. Из медицинских текстов извлекаются: названия заболеваний, симптомы, области тела, к которым относится заболевание, а также применяемые лекарственные препараты. Для извлечения знаний использованы медицинские тезаурусы, набор вручную составленных шаблонов, а также различные методы на основе машинного обучения.

Особенностью рассмотренного решения является применение методов глубокой иерархической разметки корпуса клинических текстов с широким привлечением экспертов предметной области. Как показывает анализ работ, проблемой является высокая трудоемкость подготовки исходных данных: создание и разметка соответствующих корпусов текстов, формирование баз правил, последующая верификация моделей машинного обучения. Перспективным является подход по извлечению знаний непосредственно из данных с помощью интеллектуальных алгоритмов, когда роль человека-эксперта сводится к верификации автоматически построенных онтологических моделей («обучение онтологий», ontology learning).

В статье рассмотрена задача анализа и разработки методов и механизмов извлечения знаний из периодически обновляемых клинических рекомендаций с целью извлечения знаний на основе технологий автоматизации построения онтологии проблемной области и формирования графа знаний.

Для решения имеющейся задачи в работе проведены следующие действия:

- во втором разделе проведен обзор известных публикаций по тематике автоматизации построения онтологий, графов знаний как

инструментов семантического моделирования проблемно-ориентированного корпуса текстов;

– в третьем разделе разработана структурно-функциональная организация системы извлечения знаний и автоматического построения онтологии и графа знаний проблемно-ориентированного корпуса для конкретной предметной области с целью последующего построения системы поддержки принятия решений при анализе клинических рекомендаций;

– в четвертом разделе представлены предварительные результаты эксперимента на корпусе медицинских текстов заданной тематики (пульмонология, история болезней пациентов) при извлечении знаний из неразмеченного корпуса медицинских текстов;

– в пятом разделе отражены анализ и обсуждение результатов исследования.

2. Методы извлечения знаний из слабоструктурированных данных на основе автоматизации построения онтологий и графов знаний

2.1. Подходы к автоматизации построения онтологий.

Онтологии приобрели большую популярность и признание и считаются качественным источником семантики и интероперабельности во всех интеллектуальных системах обработки слабоструктурированных и неструктурированных данных.

Для представления (хранения) медицинских знаний разработаны специальные онтологии, которые условно разделены на две группы [4]:

1. онтологии формирования медицинских признаков из элементарных терминов;
2. онтологии описания патологических процессов и других медицинских явлений.

Онтологии являются фундаментом для большинства существующих медицинских экспертных систем.

В традиционном подходе к построению онтологии в качестве основного источника знаний выступает эксперт – специалист в предметной области. Данный подход имеет множество недостатков, связанных с серьезными трудовыми затратами и ограниченными возможностями экспертов предметной области на этапе сбора, подготовки и последующего анализа данных.

Бизнес-процессы современной цифровой экономики генерируют значительные объемы данных, что существенно снижает эффективность эксперта как непосредственного и единственного источника знаний. Экспоненциальный рост объемов доступных

слабоструктурированных или неструктурированных данных в глобальных и локальных базах существенно повысил актуальность проблемы автоматического получения онтологии на основе анализа проблемно-ориентированных корпусов текстов [12].

Становится перспективным подход по извлечению знаний непосредственно из существующих структурированных и неструктурированных источников данных с помощью методов и технологий интеллектуального анализа [13]. При реализации данного подхода для человека-эксперта отводится роль проектирования концептуальных верхнеуровневых абстракций, частичная разметка исходных данных и валидация полученных результатов (верификация автоматически построенных онтологических моделей).

В [14] предлагается несколько методологий, использующих методы из различных областей (машинное обучение, интеллектуальный анализ текста, представление знаний и рассуждения, поиск информации и обработка естественного языка), для обеспечения определенного уровня автоматизации процесса получения онтологий из неструктурированного текста. Описывается процесс изучения онтологий и дальнейшая классификация методов изучения онтологий на три класса (лингвистические, статистические и логические) и обсуждается множество алгоритмов в каждой категории.

В работе [15] предложено рассматривать «обучение онтологий» на основе слабоструктурированных данных как некоторую последовательность согласованных действий по извлечению знаний из данных, проектированию и построению отдельных фрагментов онтологий. Первым шагом является извлечение из текста основных терминов. Множество выделенных терминов на основе поиска синонимов трансформируется во множество концептов. Последующее структурирование концептов позволяет построить иерархию концептов. На заключительном этапе строится совокупность аксиом для проектируемой онтологии. Подобный подход позволяет строить онтологии без трудоемкого ручного проектирования, что стало возможным благодаря стремительному развитию технологий интеллектуальной обработки текстов на основе методов машинного обучения, что позволяет вывести качество извлекаемых иерархий концептов на принципиально новый уровень. Предваряющие исследования основывались на базовой версии онтологии, разработанной экспертами вручную, на основе которой выполнено извлечение знаний из слабоструктурированных текстовых данных с помощью методов машинного обучения [16].

В работе [17] описаны подходы к обучению онтологий на основе анализа метаданных и контекста слабоструктурированного содержания. Предложена модель совместного представления контента и его метаданных в системе управления контентом. Для извлечения терминов был использован ансамблевый метод. Описаны методы построения таксономических отношений на основе векторного представления слов и нетаксономических отношений на основе анализа универсальных зависимостей с помощью алгоритмов обработки естественного языка с применением машинного обучения.

В работе [18] предложена схема применения методов кластеризации в задаче формирования концептов на основе кластеров семантически замкнутых терминов. Для решения проблемы построения кластеров, специфичных для конкретной предметной области или при определении соответствующих концептуальных обозначений для каждого кластера, предложено использовать основные понятия из онтологии предметной области в качестве предварительных знаний и адаптировать кластеризацию терминов с помощью моделей LDA (Latent Dirichlet allocation – латентное размещение Дирихле), основанных на начальных знаниях, чтобы учесть эти основные понятия. На первом этапе выделенная тема связана с набором начальных терминов одной основной концепции, затем обучение модели руководствуется этими начальными понятиями, чтобы собрать в одной и той же теме термины, которые относятся к ее основной концепции.

Предлагаемый в [19] подход автоматизирует процесс создания баз знаний, основываясь на принципах адаптивности к специфике проблемной области экспертизы, аспектам рассматриваемой задачи и глобальным базам знаний. Приводится онтологически управляемая архитектура инструментальной среды, автоматизирующей создание продукционных экспертных систем. На основе заданных с помощью онтологий сценариев естественно-языкового диалога процесс извлечения знаний позволяет существенно снизить трудозатраты эксперта и инженера по знаниям на построение и верификацию базы знаний.

В статье [20] рассматриваются вопросы применения алгебраических методов представления и обработки знаний в медицинских интеллектуальных информационных системах. Для представления знаний предлагается использовать аппарат E-структур для построения процедур обеспечения целостности баз знаний.

Статья [21] посвящена обобщению методов обработки текстов на естественном языке, в основе которых лежит формирование и

использование ассоциативно-онтологического представления данных. Предлагаемый метод расширяет методы лингвистической статистики и логико-статистические методы для извлечения знаний и построения ассоциативной онтологии заданной предметной области.

В работе [22] предложена методика обработки обращений пациентов на основе применения инфологической системы, позволяющей организовать выявление семантического содержания жалоб на состояние здоровья. В основу предлагаемой методики положен инфологический подход к обработке текстовых документов на основе итерационного процесса формирования тематических знаний посредством формирования тематических антологий – т.е. на основе предметно-ориентированных корпусов, их тезаурусов и глоссариев производится уточнение области и оценка сходства с ними новых текстовых документов.

Рассмотренные работы по автоматизации построения онтологий предлагают различные подходы и инструментарий для снижения нагрузки на экспертов предметной области и инженеров по знаниям, однако, как отмечается в актуальных исследованиях, применение моделей машинного обучения и интеллектуального анализа позволит на основе тонкой настройки существующих нейросетевых лингвистических моделей, построенных на обобщенных корпусах текстов, существенно повысить качество анализа исходных, «сырых» слабоструктурированных данных и снизить требования к предварительно построенным глоссариям и кодификаторам [23, 24, 25, 26].

2.2. Языковые модели в контексте инженерии знаний.

Предобученные языковые модели обладают знаниями об отношениях, содержащихся в обучающей выборке [24]. В [27] отмечается, что языковые модели имеют множество преимуществ перед структурированными базами знаний, например, в том, что они не требуют проектирования структуры, свободно расширяемы новыми данными и не требуют предварительной разметки.

Предобученные языковые модели BERT [28] демонстрируют существенно более высокие результаты в решении задач обработки естественного языка. Для существующих версий предобученных языковых моделей семейства BERT особо актуальным является вопрос модификации и разработки методов непрерывной тонкой настройки и аугментации внешними данными для поддержания их актуальности в решаемых задачах с наименьшими временными затратами [24].

Модель BioBERT [29] предварительно обучена на корпусе медицинских текстов (аннотации статей PubMed и PMC) и широко

используется для решения задач извлечения именованных сущностей (Named Entity Recognition, NER), извлечения отношений между сущностями (Relationship Extraction, RE) и построения вопросно-ответных систем (Question Answering System, QA).

Клинические заметки содержат информацию о пациентах, которая выходит за рамки структурированных данных, таких как лабораторные показатели и лекарства. Тем не менее, клинические записи использовались недостаточно по сравнению со структурированными данными, поскольку они очень многомерны и разрежены.

Модель ClinicalBERT [30] – это вариант BERT, предобученный на корпусе клинических документов. Модель способна выделять отношения между медицинскими концепциями. Модель предварительно обучена на наборе данных Medical Information Mart for Intensive Care III из электронных медицинских карт 58 976 уникальных госпитализаций 38 597 пациентов в отделении интенсивной терапии в период с 2001 по 2012 год. Содержит 2 083 180 обезличенных заметок, связанных с госпитализациями. Модель Bio-Discharge-Summary [30] является дообученным вариантом BioBERT и предназначена для решения нескольких задач обработки слабоструктурированных проблемно-ориентированных текстов с минимальными архитектурными модификациями.

В работах [31, 32] представлен полноразмерный русскоязычный корпус отзывов пользователей Интернета со сложной маркировкой NER, а также оценка уровней точности, достигнутых в этом корпусе нейронными сетями глубокого обучения для извлечения фармакологически значимых сущностей из русских текстов: Medication (33005 высказываний), Adverse Drug Reaction (1778), Disease (17403), и Note (4490).

В работе [33] представлен российский корпус реакций на лекарства (The Russian Drug Reaction Corpus, RuDRcC) – частично аннотированный корпус отзывов потребителей на русском языке о фармацевтических продуктах для выявления именованных объектов, связанных со здоровьем, и эффективности фармацевтических продуктов. Представлена базовая модель для задач распознавания именованных сущностей (NER) и классификации предложений с несколькими метками в этом корпусе. Макро-оценка меры F_1 в задаче NER составляет 74,85% и была достигнута с помощью модели RuDR-BERT.

Разработанный в [1] метод позволяет находить в тексте различные варианты использования медицинских терминов по

заданным кодификаторам, аналогично системе MetaMap [34]. В качестве кодификаторов использовались Unified Medical Language System (UMLS) Metathesaurus [35] (русскоязычный вариант представлен MeSH в [36]), а также подготовленный государственный реестр лекарственных средств [37].

В работе [38] рассмотрена задача обработки текстов и подготовки моделей векторизации для классификации научных текстов по научной специальности. Проведено сравнение разных способов подготовки текстов и выявлена наиболее эффективная их комбинация, приведены результаты векторизации корпуса текстов на основе метод TF-IDF, оценено влияние гиперпараметров на результаты классификации с помощью предложенной модели машинного обучения.

В работе [1] создан размеченный корпус клинических текстов на русском языке. В состав корпуса вошли более 120 деперсонализированных историй болезни пациентов педиатрического центра с аллергическими, ревматическими и нефрологическими заболеваниями, а также болезнями органов дыхания. При составлении инструкций по разметке учитывался опыт зарубежных семинаров, таких как CLEF eHealth [39], для которых создавались схожие ресурсы. Специалисты в области медицины разметили в корпусе более 18 000 сущностей, а также более 12 000 атрибутов и связей. Оценки метода извлечения лекарственных препаратов из клинических текстов: точность – 84,3%, полнота – 74,6%, F₁-мера – 79,2%.

В работе [26] рассматривается новый способ извлечения понятий из текстов предметной области на основе комбинации анализа формальных понятий и бутстрап-технологии информационного поиска. Предложен новый способ автоматического извлечения понятий из текстов медицинской тематики, основанный на заполнении пропусков в сильно разреженных матрицах совместной встречаемости терминов, удовлетворяющих лексико-синтаксическим шаблонам вида «Существительное + Существительное» или «Существительное + Существительное в родительном падеже».

Анализ работ показывает, что для англоязычного домена документов созданы и исследованы как проблемно-ориентированные корпуса текстов, так и передовые языковые модели, предназначенные для решения целого спектра задач анализа слабоструктурированных данных. Для русскоязычного домена предприняты успешные попытки создания корпусов документов и построения языковых моделей, однако их использование для построения онтологических моделей и графов знаний изучено недостаточно – требуются значительные

усилия для расширения и разметки корпусов специализированных текстов, построения глоссариев и применения методов выделения NER и связей между сущностями для качественного перехода к автоматизированным вариантам построения онтологий.

2.3. Граф знаний как инструмент семантического моделирования проблемно-ориентированного корпуса текстов. Основываясь на онтологии, граф знаний позволяет формализовать и интегрировать гетерогенные источники данных и знаний в общую базу, одновременно обеспечивая их непротиворечивость.

Граф знаний (Knowledge Graph, KG) [40] – это структурированное графическое представление семантических знаний и отношений, где узлы в графе представляют сущности, а ребра представляют отношения между ними. Построение графа знаний предполагает извлечение связей из неструктурированного текста с последующим эффективным хранением в граф-ориентированных базах данных. Современное использование графов знаний возникло и развивалось в рамках направления Semantic Web [41], во многих работах граф знаний определяется как множество «триплет» в виде (субъект, предикат, объект), образующих RDF-граф [42, 43], в котором вершинами являются субъекты и объекты, а рёбра отображают отношения между ними. Модель данных RDF (Resource Description Framework – «среда описания ресурса») [44] является утверждением о ресурсах (информационные и неинформационные сущности) в машиночитаемом формате и имеет вид «субъект предикат – объект» (триплет) (рисунок 1).




Рис. 1. Триплет RDF

Возможная структура триплета имеет следующий вид: СУБЪЕКТ (например, инсулин), ПРЕДИКАТ (например: может понижать), ОБЪЕКТ (например: уровень глюкозы в крови).

В [40] показано, что граф знаний должен быть источником достоверного знания, а не набором утверждений.

Особенностью графа знаний является не только способ представления знаний, но и способ получения новых знаний [45, 46]: «граф знаний собирает и интегрирует информацию в онтологию и применяет подсистему вывода для получения новых знаний». Существует множество исследований, предлагающих механизмы порождения нового знания: логические методы, основанные на

применении правил вывода [47] и статистические методы, основанные на векторных вложениях (embeddings) графов знаний [48], а также различные комбинации этих двух методов. В обзоре [24] показано, что крупномасштабные графы знаний эффективно используются для решения следующих задач: семантический поиск, поддержка принятия решений и генерирование ответов на вопросы [49]. Особо отмечено, что понятие «граф знаний» можно считать синонимом «базы знаний» [50] или «понятием, находящимся на уровень выше понятия базы знаний» [51].

Концепция открытых графов знаний была впервые реализована в 2007 г. в базе знаний DBpedia [52], построенной на основе интеллектуального анализа статей из онлайн-энциклопедии Wikipedia [53]. Непосредственно термин «граф знаний» введен компанией Google и связан с предложенным решением Google Knowledge Graph [54, 55].

Графы знаний, такие как Freebase и YAGO, широко используются в различных задачах обработки естественного языка (Natural Language Processing, NLP). Обучение представлению графов знаний направлено на отображение сущностей и отношений в непрерывное низкоразмерное векторное пространство. Обычные методы встраивания KG используют только триплеты KG и, таким образом, страдают от разреженности структуры. Проблема решается путем включения вспомогательных текстов сущностей, обычно описаний сущностей. Однако эти методы обычно фокусируются только на локальных последовательных последовательностях слов, но редко явно используют глобальную информацию о совпадении слов в корпусе.

Одной из самых больших проблем современной медицины является предоставление соответствующих, персонализированных и точных диагнозов и методов лечения на основе обработки данных, необходимых для персонализации медицины. В статье [56] рассмотрен подход к персонализации подбора лечения на основе графа знаний.

В работе [55] предлагается моделировать весь вспомогательный текстовый корпус и представить сквозную модель встраивания KG с улучшенным текстовым графом.

В работе [57] предложен метод извлечения отношений с использованием семантической регулярности в распределенном пространстве вложения векторов слов. Такой полууправляемый подход не зависит от синтаксиса языка и может быть использован для извлечения отношений из любого языка. Исследованы различные показатели сходства для маркировки извлеченных отношений оценкой достоверности семантической связи.

В работе [58] описывается система представления и интеллектуального анализа знаний, названная авторами семантическим графом знаний. В основе семантического графа знаний лежит использование инвертированного индекса наряду с дополнительным не инвертированным индексом для представления узлов (терминов) и ребер (документов в списках пересекающихся проводок для нескольких терминов/узлов). Предлагаемый семантический граф знаний способен динамически обнаруживать и оценивать взаимосвязи между заданным множеством сущностей посредством динамического создания множества вершин и ребер из компактного графа, автоматически сформированного в процессе анализа корпуса текстовых данных проблемной области.

В работе [59] предложено расширенное представление масштабируемого графа знаний на основе автоматического извлечения информации из корпуса новостных статей и анализ возможности использования графа знаний в качестве эффективного приложения для анализа и генерации представления знаний из извлеченного корпуса. Граф знаний состоит из базы знаний, построенной с использованием триплетов – выделенных отношений.

В работе [60] исследуется идея навигации по семантическим связям между извлеченными объектами как способ поиска в текстовом корпусе.

В работе [61] рассматриваются возможности применения концептуальных графов знаний для семантической разметки корпусов текстов. Построение метаданных на основе подобной разметки направлено на совершенствование алгоритмов решения определенных классов задач извлечения знаний и слабоструктурированных текстов. Предложен алгоритм автоматического построения концептуальных графов знаний, приводятся результаты экспериментов на текстах аннотаций научных статей.

В [62] предложена Knowledge Graph Language Model (KGLM) – нейросетевая языковая модель, аугментированная механизмами выбора и копирования информации из внешнего графа знаний, способная обращаться к внешнему источнику фактов, для генерирования фактически корректного текста. KGLM, в отличие от других новейших языковых моделей, требует размеченного набора обучающих данных.

В [63] предлагают методику предобучения Retrieval-Augmented Language Model (REALM), аугментирующую алгоритмы предобучения языковых моделей обученной системой поиска текстовых знаний. Как утверждают авторы, в отличие от моделей, которые содержат знания в своих параметрах, их подход эксплицитно выявляет роль знаний, так

как модели требуется решить, какие знания ей потребуются для рассуждений.

В [64] авторы отмечают, что, несмотря на значительный успех предобученных языковых моделей в эмпирических исследованиях, такие модели, будучи предобученными без учителя, не справляются с извлечением больших объемов знаний. Кроме того, авторы подчеркивают трудности, связанные с «внедрением» многообразных знаний в единую предобученную модель с помощью изменения исходных параметров таких моделей, в частности, риск катастрофической забывчивости.

В [65] приведены недостатки традиционных методов использования баз знаний для улучшения производительности рекуррентных нейронных сетей в задачах машинного чтения – низкая способность к обобщению признаков и необходимость конструирования признаков для достижения оптимальной производительности в отдельных задачах.

В [66] указано, что в совокупности связей между вершинами графов знаний содержатся дополнительные знания, в то же время, традиционные методы обучения на представлениях знаний (Knowledge Representation Learning, KRL) используют только триплеты, игнорируя контекстуализированную информацию. Предложена модель BERT-MK (BERT-based language model with Medical Knowledge) – предобученная языковая модель BERT, тонко настроенная с помощью обучения на крупномасштабном медицинском корпусе и аугментированную медицинскими знаниями, с помощью представлений, построенных на основе авторского подхода.

В [67] утверждается, что предобученные языковые модели наподобие BERT и RoBERTa, несмотря на высокие результаты в задачах обработки текста на естественном языке и способности к извлечению лингвистических знаний из неразмеченных текстовых корпусов, как правило, недостаточно способны к захвату фактов о мире. Авторы предлагают рассмотреть взаимную аугментацию языковых моделей с графами знаний, предлагая модель Knowledge Embedding and Pre- Trained Language Representation (KEPLER).

В [68] авторы раскрывают проблему завершенности графов знаний и процесса их дополнения на основе оценки правдоподобности новых триплетов. Авторы предлагают рассматривать триплеты как текстовые последовательности и представляют Knowledge Graph Bidirectional Encoder Representations from Transformer (KG-BERT) – предобученную языковую модель BERT, дообученную для решения задачи оценки достоверности триплетов и их отношений.

Концептуальная модель графа знаний в [69] включает следующие сущности:

- «**POSOLGY**» – описание схемы назначения лекарственного препарата и дополнительные атрибуты (dosage, duration, form, frequency, route of administration of the drug (route), name and identifier (id) of this node and special attribute (pos));

- «**PATIENT**» – пациент;

- «**DRUG**» – лекарственный препарат и атрибуты (the drug concentration (Strength), the node identifier, and the drug name and the special attribute (str));

- «**ADE**» – побочные эффекты и атрибуты (the name of the side effect and the node identifier);

- «**REASON**» – причина назначения и его атрибуты: the name of the reason and the node identifier,

что позволяет извлекать и формализовывать на основе техник выделения NER и отношений между сущностями с помощью предобученных моделей BERT знания о схемах лечения в виде графа знаний.

Таким образом, в науке и практике семантического анализа текстов накоплены определённые результаты, которые позволяют решать различные задачи. Задача извлечения знаний из медицинских текстов имеет свою специфику:

- для русскоязычного сегмента представлены лишь отдельные достаточно скромные по размеру корпусы размеченных медицинских текстов, что объясняется высокой трудоёмкостью их сбора и отсутствием общепринятого протокола разметки (по сравнению с англоязычными решениями), учитывающего структуру и номенклатуру отечественной документации;

- отдельной проблемой является формирование открытых кодификаторов и глоссариев именованных сущностей для построения моделей NER и дальнейшей автоматизации конструирования графов знаний (для русскоязычного сегмента);

- недостаточное количество полилингвальных языковых предметно-ориентированных моделей семейства BERT, T5 и т.д.;

- необходимость интеграции и адаптации методов построения графовых моделей, языковых моделей и традиционных моделей баз знаний из других предметных областей.

3. Система извлечения знаний и автоматического построения онтологии и графа знаний проблемно-ориентированного корпуса клинических текстов. Знания являются динамической структурой, имеющей свой жизненный цикл, что

требует постоянной модификации и обновления данных в графах знаний на основе применения комплекса методов машинного обучения [70].

Основные этапы извлечения знаний и динамического обновления графа знаний включают:

1. распознавание/извлечение именованных сущностей (Named Entity Recognition/Extraction) – разграничение позиций упоминаний сущностей во входном тексте;

2. связывание/снятие омонимии сущностей, или семантическое аннотирование (Entity Linking/Disambiguation, Semantic Annotation) – ассоциирование упоминаний сущностей с подходящим и однозначным идентификатором в базе знаний;

3. извлечение терминов (Term Extraction) – извлечение основных фраз, которые обозначают концепты, релевантные к выбранной предметной области и описанные в корпусе, иногда включая иерархические отношения между концептами;

4. извлечение ключевых слов/фраз (Keyword/Keyphrase Extraction) – извлечение основных фраз, которые позволяют категоризировать тематику текста (в отличие от извлечения терминов, задача извлечения ключевых фраз заключается в описании именно текста, а не предметной области). Ключевые фразы также могут быть связаны с базой знаний;

5. тематическое моделирование/классификация (Topic Modeling, Classification) – кластеризация слов/фраз, которые часто встречаются совместно в сходном контексте. Эти кластеры затем ассоциируются с более абстрактными темами, с которыми связан текст;

6. маркирование/идентификация темы (Topic Labeling/Identification) – для кластеров слов, идентифицированных как абстрактные темы, извлечение одиночного термина или фразы, наилучшим образом характеризующей эти темы;

7. извлечение отношений (Relation Extraction) – извлечение потенциальных n-арных отношений из неструктурированных или полуструктурированных (таких как HTML-таблицы) источников.

На основе анализа основных этапов извлечения знаний и динамического обновления графа знаний предложена структурная схема системы автоматизированного построения онтологий и графов знаний (рисунок 2).




Рис. 2. Структурная схема системы автоматизированного построения онтологий и графов знаний (ML – модели машинного обучения, GUI – графический пользовательский интерфейс, NLP – обработка естественного языка, KG – граф знаний)

Модуль (1) построения проблемно-ориентированного корпуса текстов на основании данных их внешних источников ($БД_1$ — специализированные тексты — клинические описания и истории болезней пациентов, включая: эпикризы, результаты функциональной диагностики, осмотров и рекомендации врачей по лечению и $БД_2$ — описания клинических рекомендаций по лечению) позволяет собирать в документ-ориентированной $БД_с$ текстовые документы. Предварительная обработка и фильтрация собранных данных проводится в модуле (2) с помощью инструментов символьной фильтрации, фильтрации с помощью стоп-словарей и удаления нерелевантных фрагментов текстов, также применяются нейросетевые модели лемматизации (приведения в исходную форму) и стемминга, частеречной разметки. Модуль (3) позволяет извлекать из корпуса текстов с помощью инструментов NLP основные термины предметной области, сформировать кортеж основных концептов и их предварительную иерархию.

Модуль (4) позволяет выполнить предварительную структурно-семантическую разметку для выделения списка аннотаций, характеризующих заболевания, симптомы, лекарственные препараты, методы лечения, результаты применения методов лечения и т.д. Разметка выполняется с привлечением специалистов предметной области и специалистов по обработке естественно-языковых текстов (14) посредством графической консоли (5). Специалист корректирует предварительно выделенные термины и иерархию концептов, собранные в граф-ориентированной БД₃.

Модуль (8) построения векторного представления документов на различных уровнях – от символьного до уровня отдельных текстов – с помощью нейросетевых моделей вложений позволяет получить формализованные текстовые описания, используемые для дальнейшей оценки семантического сходства и корректировки иерархии концептов. Построение векторного представления выполняется с помощью дообучаемых моделей машинного обучения, обновляемых и подготовленных в БД_{ML} под контролем специалиста (15) по анализу и извлечению знаний из корпуса, корректирующего процесс посредством консоли (6).

Модуль (10) позволяет для предварительно размеченного (автоматически и с привлечением эксперта) корпуса текстов формировать триплеты «объект»-«действие»-«субъект», на основании анализа которых строится «сырой» граф знаний. Модуль (9) выполняет построение нетаксономических и таксономических отношений для иерархии выделенных концептов и фрагментов текстов, что позволит перейти к более качественному построению графа знаний в модуле (7) формирования аксиом на основе индуктивно-логического подхода. Верификация множества сформулированных аксиом и фрагментов графа знаний (11) с привлечением специалиста предметно области (16) посредством графического интерфейса консоли доступа (12) позволяет отфильтровать нерелевантные данные в граф-ориентированной БД_{KG}, предназначенной для хранения графа знаний.

Модуль (13) в процессе построения аксиом и формирования «сырого» графа знаний на основе триплетов позволяет представить иерархию концептов и отношений в виде автоматически построенной онтологии анализируемой проблемной области.

На рисунке 3 представлен верхний уровень функциональной модели автоматизированного построения онтологии и графа знаний, раскрывающий процесс сбора и обработки текстовых данных.

Декомпозиция процесса автоматизированного построения онтологий и графа знаний приведена на рисунке 3.

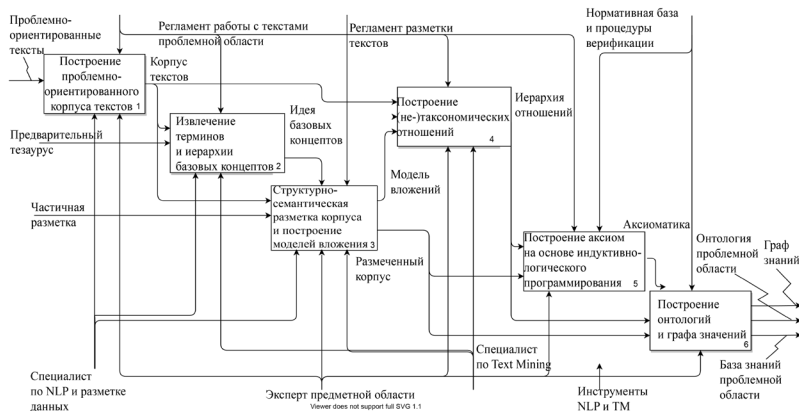


Рис. 3. Первый уровень декомпозиции функциональной модели процесса автоматизированного построения онтологии и графа знаний (NLP – обработка естественного языка, ТМ – извлечение знаний из текстов)

Первый уровень декомпозиции реализует основные этапы извлечения знаний и динамического обновления графа знаний с учетом задействованных ресурсов и инструментов, ограничений и условий использования, а также формируемого потока промежуточных данных. Структурно-функциональная организация позволяет перейти к проектированию архитектуры прототипа программной системы.

4. Эксперимент автоматизированного построения онтологии и графа знаний для корпуса проблемно-ориентированных текстов. Исходный корпус текстов проблемной области детально описан в [71, 1] и включает 162 документа обезличенных историй болезни пациентов педиатрического центра с болезнями органов дыхания, с аллергическими, нефрологическими и ревматическими болезнями. Пример документа – клинического описания – приведен ниже:

'ДИАГНОЗ: Бронхиальная астма, атопическая форма, легкое интермиттирующее течение, неполная ремиссия. Круглогодичный аллергический ринит, ремиссия. Идиопатическая эпилепсия. Нарушение эмоционально-волевой сферы. Парциальный дефицит когнитивных функций. Ангиопатия сетчатки обоих глаз со спазмом артерий. Хронический компрессионный тонзиллит. Остеохондропатия позвоночника. <...>'

Комплекс алгоритмов обработки и структуризации текстовых данных, извлечения внутренней структуры на уровне частей документа (разделы, абзацы, предложения), частичечной разметки, семантической

разметки (извлечение именованных сущностей, терминов), нормализации и формализации на основе алгоритмов векторных вложений различного уровня с привлечением нейросетевых предобученных моделей позволяет выполнить для данного корпуса текстов основные этапы предобработки и формализации с применением известных инструментов [72, 73] описан в таблице 1.

Таблица 1. Структура конвейера NLP-конвейер

Этап	Шаги	Действия	Инструменты
Предобработка	Символьная фильтрация	Удаление нерелевантных символов, HTML-тегов	Набор регулярных выражений
	Токенизация	Разбивка текста на токены с помощью предобученной для русского языка нейросетевой модели	Razdel (фреймворк Natasha), Spacy, Stanza, nltk
	Фильтрация нерелевантных токенов	Удаление ссылок, нерелевантных сокращений	Регулярные выражения
Нормализация	Лемматизация	Приведение слов в исходную форму с помощью предобученной нейросетевой модели	Morph (фреймворк Natasha), pymorphy2, spacy
Постобработка	Частеречная фильтрация	Остаются только существительные, глаголы, прилагательные, наречия, местоимения	Morph (фреймворк Natasha)
	Извлечение именованных сущностей	Разметка тегами выделенных типов именованных сущностей	Natasha, spacy
	Фильтрация на основе стоп-словарей	Фильтрация нерелевантных лемм с помощью составного стоп-словаря, включающего наиболее часто встречающиеся слова корпуса текстов	NLTK-russian, english
	Формирование документа-строки	Объединение лемм в нормализованную строку-документ	

Например, расширенный стоп-словарь включает 343 токена: 'мм', 'мг', 'р', 'д', 'г', 'чсс', 'ст', 'год', 'рт', 'фв' и т.п.

В качестве разрешенных тегов частеречной разметки [74, 75] и последующего построения триплетов «объект»-«действие»-«субъект» использован кортеж: ['ADV', 'VERB', 'ADJ', 'NOUN', 'PROPН'] (таблица 2). Выбор тегов зависит от специфики текстового корпуса и может быть иным.

Таблица 2. Теги частеречной разметки


Тег-POS	Описание	Пример
ADJ	adjective, имя прилагательное	большой, старый, зеленый, непонятный
ADV	adverb, наречие	очень, завтра, вниз
AUX	auxiliary, вспомогательный глагол	есть, будет
NOUN	noun, имя существительное	девушка, кошка, земля
NUM	numeral, имя числительное	1, 20200, один, двадцать восемь, IV, MMXIV
PRON	pronoun, местоимение	я, ты, он, она, я, себя, кто-то
PROPН	proper noun, имя собственное	РФ, Людвиг Витгенштейн
VERB	verb, глагол	бежать, бежит, ест

Пример фрагментов исходных текстов, их префильтрованный и нормализованный вид приведены в таблице 3.

В процессе анализа строится словарь корпуса текстов, визуализация которого в виде «облака слов» и диаграммы вхождения в корпус приведены на рисунке 4. «Облако слов» является удачным инструментом разведочного анализа, позволяющим визуально оценить частотность распределения ключевых слов и словосочетаний. Последующий количественный анализ диаграмм вхождения позволяет уточнить стоп-словарь и необходимость корректировки разметки.

Таблица 3. Иллюстрация фрагментов исходных, префилтрованных и нормализованных текстов корпуса

	Фрагменты исходных текстов	Префилтрованные тексты	Нормализованные тексты
0	НАХОДИЛСЯ НА ЛЕЧЕНИИ С 9.10.41 ПО 20.10...	находился на лечении с по г диагно...	[находиться, лечение, 20.10.41, диагноз, по...
1	ВОЗРАСТ: 9 лет (16.01.2021). \nНАХОДИЛСЯ НА ЛЕЧ...	возраст лет находился на лечении с ...	[возраст, год, находиться, лечение, 26.02.2031...
2	ДИАГНОЗ: Бронхиальная астма, атопическая, легк...	диагноз бронхиальная астма атопическая ...	[диагноз, бронхиальный, астма, атопический, ле...
3	ДИАГНОЗ: Бронхиальная астма, атопическая форма...	диагноз бронхиальная астма атопическая ...	[диагноз, бронхиальный, астма, атопический, фо...
4	ДИАГНОЗ: Бронхиальная астма, тяжелое персисти...	диагноз бронхиальная астма тяжелое пер...	[диагноз, бронхиальный, астма, тяжелый, персис...






Рис. 4. Визуализация частотного словаря корпуса текстов в виде «облака слов»: а) «облако слов» для корпуса текстов; б) диаграмма наиболее часто встречающихся слов (нормализованная форма)

Одной из обозначенных в ходе анализа проблем была названа трудоемкость выделения именованных сущностей и необходимость глубокой иерархической разметки корпуса текстов. Далее оценивается применение распространенных для русскоязычного домена моделей выделения именованных сущностей на основе нейронных сетей

(рекуррентных и глубоких архитектур), представленных в фреймворках Natasha и spacy, общего назначения (таблица 4).

Таблица 4. Количественный анализ выделенных именованных сущностей в корпусе текстов

Параметр	Характеристика			
	Natasha	Spacy	Базовый вариант I [1]	Модель II [1]
Количество выделенных именованных сущностей	773	1164	-	-
Общее пересечение	335		-	-
Оценка меры выделения именованных сущностей F1	20,4 %	19,1 %	16,7 %	81,9 %
Пример выделяемых именованных сущностей (с меткой типа)	'Квинке': 'PER', 'ГКС': 'ORG', 'Институте иммунологии': 'ORG', 'ОВЛД': 'ORG', 'АБ': 'ORG', 'ЗОД': 'ORG', 'ФВД': 'ORG', 'НИИ педиатрии': 'ORG', 'И.И. Балаболкина': 'PER', 'Зев': 'PER', 'НИЦЗД РАМН': 'ORG',	'АЛТ': 'ORG', 'Цитофлавин': 'PER', 'НИИ паразитологии': 'ORG', 'МБТ': 'ORG', 'Великий Новгород': 'LOC', 'Смекта': 'PER'	-	-

Из таблицы видно, что модели общего назначения, не дообученные на размеченном корпусе, не позволяют приблизиться по качеству выделения именованных сущностей к специализированным моделям, однако позволяют предварительно разметить корпус для дальнейшей верификации и уточнения разметки.

Формализованное представление текстов получено с помощью предобученной модели-трансформера BERT Large Model Multitask (cased) for Sentence Embeddings in Russian Language – предложенная специалистами RnD NLP SberDevices модель-трансформер многозадачного обучения для построения универсальной модели естественного языка на основе модели SBERT. T-SNE проекция формализованного корпуса текстов представлена на рисунке 5.




Рис. 5. T-SNE проекция формализованного с помощью предобученной модели-трансформера BERT корпуса текстов

Из рисунка видно, что тексты сгруппированы в устойчивые кластеры по степени их семантического сходства, что позволяет положительно оценить предыдущие этапы предобработки, нормализации и формализации текстовых описаний.

Автоматическое выделение триплетов «объект»-«действие»-«субъект» на основе частеречной разметки корпуса текстов позволяет выделить атомарные фрагменты «сырого» графа знаний. Основой триплетов являются зависимости [76, 77], представленные в таблице 5. Выбор зависимостей обусловлен тематикой и окраской текста.

Таблица 5. Универсальные синтаксические отношения для построения триплетов

Отношение	Пояснение отношения
nsubj	Именное подлежащее, которое является синтаксическим подлежащим.
nsubj:pass	Именная группа, которая является синтаксическим подлежащим пассивного предложения.
obj	Именная группа, обозначающая объект, на который воздействуют или который претерпевает изменение состояния или движения.
obl	Отношение используется для именных (существительное, местоимение, именное словосочетание), функционирующих как неосновной (косвенный) аргумент или дополнение.
nmod	Отношение используется для номинальных зависимостей другого существительного или именной фразы и функционально соответствует атрибуту или дополнению родительного падежа.
nummod	Числовой модификатор существительного — это любая числовая фраза, которая служит для изменения значения существительного с помощью количества.

Как правило, Subject и Object являются существительными, а Relation – глаголом.

Фрагмент исходной базы триплетов приведен в таблице 6.

Таблица 6. Фрагмент исходной базы триплетов

	Полное предложение	subject	verb	object	Subj (нормальная форма)	Obj (нормальная форма)
0	ЭПИКРИЗ Ребенок поступил в отделение впервые с...	ЭПИКРИЗ	поступил	отделение	эпикриз	отделение
1	НАХОДИЛСЯ НА ЛЕЧЕНИИ с 26 02 2031 по 4 02 2...	ДИАГНОЗ	НАХОДИЛСЯ	ЛЕЧЕНИИ	диагноз	лечении
2	ЭПИКРИЗ Ребенок поступил в отделение впервые с...	ЭПИКРИЗ	поступил	отделение	эпикриз	отделение
3	ЭПИКРИЗ Ребенок поступил в отделение повторно ...	ЭПИКРИЗ	поступил	отделение	эпикриз	отделение
4	ЭПИКРИЗ Мальчик поступил в клинику впервые с ...	Мальчик	поступил	клинику	мальчик	клинику

Фрагмент базы триплетов после фильтрации представлен в таблице 7.

Таблица 7. Фрагмент базы триплетов после фильтрации

	Subj (нормальная форма)	Obj (нормальная форма)	verb	Полное предложение
1	проба	фтизиатром	запрещена	Проба запрещена фтизиатром
2	орви	форме	болел	Дважды болел ОРВИ в легкой форме в марте 2054...
3	талия	ушка предсердие	сглажена	Талия сердца сглажена за счет ушка левого пред...

	Subj (нормальная форма)	Obj (нормальная форма)	verb	Полное предложение
4	галотерапия	условиях галокамера	Рекомендовано	Консультация врача физиотерапевта Рекомендова...
5	бронх	уровня ветвь	прослежены	Бронхи прослежены до уровня субсегментарных ве...
6	бронх	уровня ветвь	прослежены	Бронхи прислежены до уровня субсегментарных ве...
7	бронх	уровня ветвь	прослеживаются	Бронхи прослеживаются до уровня субсегментарн...
11	девочка	улучшением	выписана	Девочка выписана с улучшением
12	мальчик	терапию стационар	получал	Мальчик регулярно получал терапию в стационаре...
18	лимфоузел	сторон	структурны	Лимфоузлы структурны с двух сторон
19	мониторирован ие	стационарных	проведено	Исследование проведено на аппарате BPLab Мони...
21	жалоба	стабильным	оставалось	За период пребывания в отделении состояние реб...
25	преднизолон	снижением доз	добавлен	Терапия в отделении Дигоксин 0 000035 мг x 2 ...
32	голова	размере	увеличена	Голова резко увеличена в размере
38	вено-венозный	признаками эпителизация	конduit	Кавапальмональный анастомоз проходим диаметро...
42	терапия	показаниям	назначена	Повторная госпитализация в НЦЗД РАМН при стаби...
54	эпикриз	отделение	поступила	ЭПИКРИЗ Девочка поступила в отделение впервые ...
63	терапия	объеме	продолжена	Терапия продолжена в прежнем объеме Следующа...
64	терапия	объеме	оставлена	Терапия оставлена в прежнем объеме После вып...

Отдельные выделенные типовые узлы «субъект», «объект», «действие» приведены ниже в порядке убывания частоты встречаемости:

знак	51
наблюдение	15
контроль	14
консультация	13
осмотр	11
госпитализация	10
инфекция	6
показатель	3
выздоровление	2
выполнение	2
отделение	2
условие	2

Выделенные триплеты (всего 162) сгруппированы в зависимости от выделенных узлов «субъект» и «объект». Вариация взаимной привязки триплетов приведена на рисунке 6.

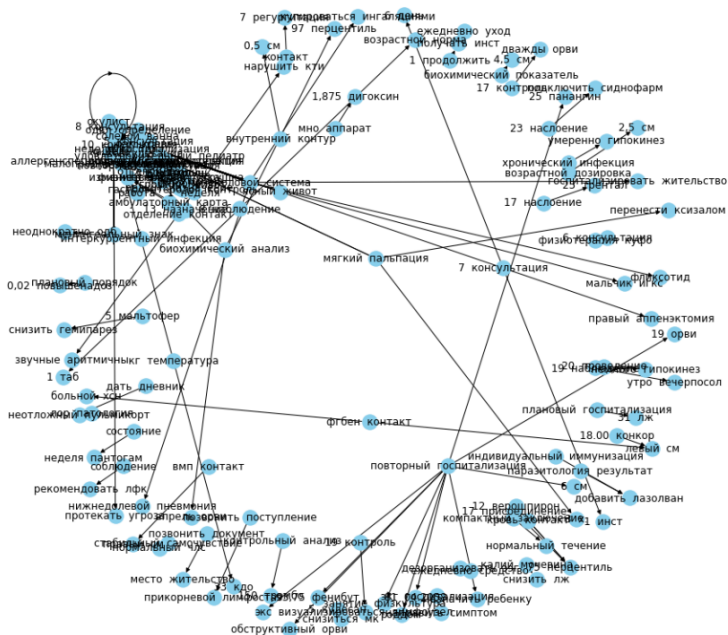


Рис. 6. Вариация взаимной привязки триплетов

Для последующего анализа и построения, например, «вопрос-ответной» системы возможно построение отдельных подграфов на основе выделенного отношения (рисунок 7 – отношение «наблюдение»).





Рис. 7. Подграф с типом ребра «наблюдение»


Далее для корпуса без предварительной разметки на основе извлеченного набора триплетов построен граф знаний (с фильтрацией по частоте встречаемости).

Фрагменты автоматически извлеченного графа знаний приведены на рисунке 8.

Дальнейшие анализ и верификация полученных триплетов при включении в конструируемую онтологию и граф знаний предлагается выполнить с помощью методов семантической оценки текстовых фрагментов, содержащихся в триплетах, с применением предобученной нейросетевой модели трансформера. Построение подобной модели требует расширенного корпуса текстов и является темой дальнейшего исследования.



а)



б)

Рис. 8. Фрагменты автоматически извлеченного графа знаний: а) Фрагмент 1 автоматически извлеченного графа знаний; б) Фрагмент 2 автоматически извлеченного графа знаний

5. Анализ и обсуждение. Проведен эксперимент на корпусе медицинских текстов заданной тематики (пульмонология, история болезней пациентов) без предварительной разметки с целью проверки предложенного решения по извлечению триплетов и конструирования на их основе графа знаний.

Показано, что модели общего назначения не позволяют приблизиться по качеству выделения именованных сущностей к специализированным моделям, однако, позволяют предварительно разметить корпус для дальнейшей верификации и уточнения разметки (оценка F1-меры для модели общего назначения – 20,4% по сравнению с вариантом использования словаря – 16,7%).

Применение языковых моделей трансформеров в сочетании с традиционным подходом по выделению триплетов, исходя из мировой практики, позволяет существенно расширить возможности по формализации знаний, построению графов знаний и решению задач построения систем поддержки принятия решений в клинической практике.

Результаты показывают необходимость более глубокой разметки корпуса текстовых документов для учета специфической лексики и обилия сокращений. На неразмеченном корпусе текстов предложенный инструмент показал свою удовлетворительную работоспособность ввиду выделения атомарных фрагментов, включаемых в автоматически формируемую онтологию.

6. Заключение. Результаты анализа проблемы извлечения знаний из периодически обновляемых клинических рекомендаций, а также анализ современного состояния подходов к автоматизации построения онтологий и графов знаний в задачах семантического моделирования проблемно-ориентированного корпуса текстов показали:

– применение моделей машинного обучения и интеллектуального анализа позволит на основе тонкой настройки существующих нейросетевых лингвистических моделей, построенных на обобщенных корпусах текстов, существенно повысить качество анализа исходных, «сырых» слабоструктурированных данных и снизить требования к предварительно построенным глоссариям и кодификаторам;

– для русскоязычного сегмента представлены лишь отдельные достаточно скромные по размеру корпуса размеченных медицинских текстов, что объясняется высокой трудоемкостью их сбора и отсутствием общепринятого протокола разметки (по

сравнению с англоязычными решениями), учитывающего структуру и номенклатуру отечественной документации;

- отдельной проблемой является формирование открытых кодификаторов и глоссариев именованных сущностей для построения моделей NER и дальнейшей автоматизации конструирования графов знаний (для русскоязычного сегмента);

- недостаточное количество полилингвальных языковых предметно-ориентированных моделей семейства BERT, T5 и т.д;

- необходимость интеграции и адаптации методов построения графовых моделей, языковых моделей и традиционных моделей баз знаний из других предметных областей.

Предлагаемая структурно-функциональная организация системы извлечения знаний и автоматического построения онтологии и графа знаний проблемно-ориентированного корпуса для конкретной предметной области основана на применении комплекса методов машинного обучения и позволяет перейти к проектированию архитектуры прототипа программной системы.

Экспериментальные исследования проведены на корпусе медицинских текстов заданной тематики (пульмонология, история болезней пациентов). Показано, что модели общего назначения позволяют предварительно разметить корпус для дальнейшей верификации и уточнения разметки, а также построения специализированных моделей (оценка F1-меры для модели общего назначения – 20,4% по сравнению с вариантом использования словаря – 16,7%). Применение языковых моделей трансформеров для выделения триплетов позволяет существенно расширить возможности по формализации знаний, построению графов знаний и решению задач построения систем поддержки принятия решений в клинической практике. Необходимым этапом является детализированная разметка корпуса текстовых документов для учета специфической лексики и обилия сокращений.

Литература

1. Баранов А.А. и др. Технологии комплексного интеллектуального анализа клинических данных // Вестник Российской академии медицинских наук. 2016. Т. 71. №. 2. С. 160-171.
2. Musen M.A., Middleton B., Greenes R.A. Clinical decision-support systems. In: Biomedical informatics. Springer. 2014. pp. 643–674. doi: 10.1007/978-1-4471-4474-8_22.
3. Rencis E. Natural language-based knowledge extraction in healthcare domain // Proceedings of the 2019 3rd International Conference on Information System and Data Mining. 2019. pp. 138-142.

4. Бледжянц Г.А., Саркисян М.А., Исакова Ю.А., Туманов Н.А., Попов А.Н., Бегмуродова Н.Ш. Ключевые технологии формирования искусственного интеллекта в медицине // Ремедиум. 2015. № 12. С. 10-15.
5. Рубрикатор клинических рекомендаций. URL: https://cr.minzdrav.gov.ru/clin_recomend (дата обращения: 01.10.2022).
6. Dligach D., Bethard S., Becker L., Miller T.A., Savova G.K. Discovering body site and severity modifiers in clinical texts. *Journal of the American Medical Informatics Association (JAMIA)*. 2014. pp. 448–454. doi: 10.1136/amajnl-2013-001766.
7. Chikka V.R., Mariyasagayam N., Niwa Y., Karlapalem K. Information Extraction from Clinical Documents: Towards Disease/Disorder Template Filling. In: *Experimental IR Meets Multilinguality, Multimodality, and Interaction*. Springer. 2015. pp. 389–401. doi: 10.1007/978-3-319-24027-5_41.
8. Shelmanov A.O., Smirnov I.V., Vishneva E.A. Information extraction from clinical texts in Russian // *Computational Linguistics and Intellectual Technologies: Papers from the Annual International Conference Dialogue (2015)*. Issue 14 (21). 2015. pp. 560–572.
9. Кушнерова И.А., Акимов С.С. Перспективы применения искусственного интеллекта в медицине // *Компьютерная интеграция производства и ИПИ-технологии: Сб. научн. тр. VIII Всероссийской научн. -практ. конф. (Оренбург, 16–17 ноября 2017 г.)*. Оренбург: ОГУ. 2017. С. 249–250.
10. Берестнева Е.В., Шаропин К.А., Жаркова О.С. Создание медицинских баз знаний с использованием деревьев решений // *Успехи современной науки*. 2016. Т. 2. № 10. С. 69–72.
11. Катасёв А.С., Ахатова Ч.Ф. Гибридная нейронечеткая модель интеллектуального анализа данных для формирования баз знаний мягких экспертных диагностических систем // *Наука и образование: научное издание МГТУ им Н.Э. Баумана*. 2012. № 12. С. 34–43.
12. Климов А.А., Куприяновский В.П., Гринько О.В., Покусаев О.Н. К вопросу обратного инжиниринга - путь от бумаги до цифровых онтологических правил для образовательных технологий // *International Journal of Open Information Technologies*. 2019. Т. 7. № 9. С. 82-91.
13. Муромцев Д., Волчек Д., Романов А. Индустриальные графы знаний - интеллектуальное ядро цифровой экономики // *Control Engineering Россия*. 2019. № 5(83). С. 32-39.
14. Asim M.N., Wasim M., Ghani Khan M.U., Mahmood W., Abbasi H.M. A survey of ontology learning techniques and applications // *Database*. 2018. vol. 2018. Bay101. <https://doi.org/10.1093/database/bay101> (дата обращения: 26.06.2022).
15. Al-Aswadi F.N., Chan H.Y., Gan K.H. Automatic ontology construction from text: a review from shallow to deep learning trend // *Artificial Intelligence Review*. 2020. Т. 53. №. 6. pp. 3901-3928.
16. Ding Y., Foo S. Ontology research and development. Part 1-a review of ontology generation // *Journal of information science*. 2002. Т. 28. №. 2. pp. 123-136.
17. Волчек Д.Г., Романов А.А. Создание и обучение онтологий на основе анализа контекста и метаданных слабоструктурированного контента // *Экономика: вчера, сегодня, завтра*. 2020. Т. 10. № 1А. С. 303–312. doi: 10.34670/AR.2020.91.1.033.
18. Huang H. et al. Core-Concept-Seeded LDA for Ontology Learning // *Procedia Computer Science*. 2021. Т. 192. pp. 222-231.
19. Минин А.С., Чуприна С.И. Методы и средства построения онтологически управляемых систем приобретения знаний // *Вестник пермского университета. Математика. Механика. Информатика*. 2021. №. 4 (55). С. 25-34.

20. Максимов А.И., Молодов В.А., Рунов С.С. Об одном способе представления знаний в медицинских интеллектуальных системах // *Современные инновации*. 2021. № 1 (39). С. 48–50.
21. Кулешов С.В., Зайцева А.А., Марков В.С. Ассоциативно-онтологический подход к обработке текстов на естественном языке // *Интеллектуальные технологии на транспорте*. 2015. № 4 (4). С. 40–45.
22. Михайлов С.Н, Малащенко О.И., Зайцева А.А. Методика инфологического анализа семантического содержания обращений пациентов для организации электронной записи // *Труды СПИИРАН*. 2015. № 5 (42). С. 140–154.
23. Harnoune A. et al. BERT based clinical knowledge extraction for biomedical knowledge graph construction and analysis // *Computer Methods and Programs in Biomedicine Update*. 2021. vol. 1. no. 100042.
24. Понкин Д.И. Концепт предобученных языковых моделей в контексте инженерии знаний // *International Journal of Open Information Technologies*. 2020. № 9. С. 18–29. URL: <http://injoit.org/index.php/j1> (дата обращения: 24.09.2022).
25. Землянский С.А., Аксёнов С.В., Лызин И.А., Берестнева О.Г. Тематическое моделирование в контексте медицинских текстов // *Доклады ТУСУР*. 2021. Т. 24. № 4. С. 58–64.
26. Нугуманова А.Б., Байбурин Е.М., Мансурова М.Е., Баракхин В.Б. Автоматическое извлечение решеток понятий из медицинских текстов на основе комбинации анализа формальных понятий и технологий бутстраппинга // *Вестник НГУ. Серия: Информационные технологии*. 2018. Т. 16. № 4. С. 140–152.
27. Petroni F., Rocktaschel T., Lewis P. Language Models as Knowledge Bases? // *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP'2019)*. org Kong (China): Association for Computational Linguistics. 2019. pp. 2463–2473.
28. Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding // *arXiv preprint arXiv:1810.04805*. URL: <https://arxiv.org/abs/1810.04805> (дата обращения: 24.09.2022).
29. Lee J., Yoon W., Kim D., Kim S., So C.H., Kang J. BioBERT: a pre-trained biomedical language representation model for biomedical text mining *Bioinformatics* // *arXiv preprint arXiv: 1901.08746*. URL: <https://arxiv.org/abs/1901.08746> (дата обращения: 24.09.2022).
30. Alsentzer E., Murphy J.R., Boag W., Weng W.-H., Jin D., Naumann T., McDermott M. Publicly available clinical bert embeddings // *arXiv preprint arXiv:1904.03323*. URL: <https://arxiv.org/pdf/1904.03323.pdf> (дата обращения: 24.09.2022).
31. Sboev A. et al. An analysis of full-size Russian complexly NER labelled corpus of Internet user reviews on the drugs based on deep learning and language neural nets // *arXiv preprint arXiv:2105.00059*. URL: <https://arxiv.org/pdf/2105.00059.pdf> (дата обращения: 24.09.2022).
32. Russian Drug Review corpus by Sag team (RDRS). URL: <https://sagteam.ru/med-corpus/stata/#ours-Pharm2021arxiv> (дата обращения: 24.09.2022).
33. Tutubalina E. et al. The Russian Drug Reaction Corpus and neural models for drug reactions and effectiveness detection in user reviews // *Bioinformatics*. 2021. Т. 37. № 2. С. 243–249.
34. Aronson A.R, Lang F.M. An overview of MetaMap: historical perspective and recent advances // *Journal of the American Medical Informatics Association*. 2010. №17 (3). pp. 229–236. doi:10.1136/jamia.2009.002733.

35. Schuyler P.L., Hole W.T., Tuttle M.S., Sherertz D.D. The UMLS Metathesaurus: representing different views of biomedical concepts // *Bulletin of the Medical Library Association*. 1993. № 81 (2). pp. 217–222.
36. Unified Medical Language System (UMLS). URL: <http://www.nlm.nih.gov/research/umls/sourcereleasedocs/current/MSHRUS/> (дата обращения: 04.10.2022).
37. Государственный реестр лекарственных средств. URL: <http://grls.rosminzdrav.ru/Default.aspx> (дата обращения: 24.09.2022).
38. Гусев П.Ю. Обработка текстов и подготовка моделей векторизации для программного комплекса классификации научных текстов // *Моделирование, оптимизация и информационные технологии*. 2021. Т. 9. № 1. С. 6–7.
39. Kelly L., Goeruiot L., Suominen H., Schreck T., Leroy G., Mowery D.L. et al. Overview of the SHARE/CLEF eHealth evaluation lab 2014 // *Springer*. 2014. pp. 172–191. doi:10.1007/978-3-319-11382-1_17.
40. McCusker J.P., Erickson J.S., Chastain K., Rashid S., Weerawarana R., Bax M., McGuinness D.L. What is a knowledge graph? URL: <https://www.semantic-web-journal.net/> (дата обращения: 25.09.2022).
41. Апанович З.В. Эволюция понятия и жизненного цикла графов знаний // *Системная информатика*. 2020. №.16. С. 57–74.
42. Färber M., Bartscherer F., Menne C., Rettinger A. Linked data quality of dbpedia, freebase, opencyc, wikidata, and yago // *Semantic Web*. 2016. pp. 1–53.
43. Huang Z., Yang J., Harmelen F.V., Hu Q. Constructing disease-centric knowledge graphs: a case study for depression (short version) // *Proceedings of the Conference on Artificial Intelligence in Medicine in Europe*. Springer. 2017. pp. 48–52.
44. World Wide Web Consortium (W3C). URL: <https://www.w3.org/> (дата обращения: 25.09.2022).
45. Ehrlinger L., Woß W. Towards a definition of knowledge graphs // *SEMANTiCS (Posters, Demos, SuCESS)*. 2016. no. 48.
46. Ernst P., Siu A., Weikum G. KnowLife: a versatile approach for constructing a large knowledge graph for biomedical sciences // *BMC bioinformatics*. 2015. № 16 (157). <https://doi.org/10.1186/s12859-015-0549-5>.
47. Stepanova D., Gad-Elrab M.H., Ho T.V. Rule Induction and Reasoning over Knowledge Graphs // *Reasoning Web International Summer School* // Springer, Cham. 2018. pp. 142–172.
48. Nickel M., Murphy K., Tresp V., Gabrilovich E. A review of relational machine learning for knowledge graphs // *Proceedings of the IEEE*, 104(1). 2016. vol. 104 (1). pp. 11–33.
49. Yao L., Mao C., Luo Y. KG-BERT: BERT for Knowledge Graph Completion // *arXiv preprint arXiv: 1810.04805*. URL: <https://arxiv.org/abs/1810.04805> (дата обращения: 24.09.2022).
50. Ji S., Pan S., Cambria E. et al. A Survey on Knowledge Graphs: Representation, Acquisition and Applications // *arXiv preprint arXiv: 2002.00388*. URL: <https://arxiv.org/abs/2002.00388> (дата обращения: 24.09.2022).
51. Yoo S.-Y., Jeong O.-K. Automating the expansion of a knowledge graph // *Expert Systems with Applications*. 2020. vol. 141. no. 112965.
52. Глобальный и единый доступ к графам знаний. URL: <https://www.dbpedia.org/> (дата обращения: 07.07.2022).
53. Википедия. Свободная энциклопедия. URL: www.en.wikipedia.org/wiki/Main_Page (дата обращения: 08.07.2022).
54. Adams T. Google and the future of search: Amit Singhal and the knowledge graph // *The Guardian*. 2013. Т. 19.
55. Ehrlinger L., Wöß W. Towards a definition of knowledge graphs // *SEMANTiCS (Posters, Demos, SuCESS)*. 2016. Т. 48. №. 1-4. p. 2.

56. Silva M.C., Faria D., Pesquita C. Matching Multiple Ontologies to Build a Knowledge Graph for Personalized Medicine // *European Semantic Web Conference*. – Springer, Cham. 2022. pp. 461-477.
57. Kumar K., Manocha S. Constructing knowledge graph from unstructured text // *Self*. 2015. Т. 3. 4 p.
58. Grainger T. et al. The Semantic Knowledge Graph: A compact, auto-generated model for real-time traversal and ranking of any relationship within a domain // *2016 IEEE international conference on data science and advanced analytics (DSAA)*. IEEE. 2016. pp. 420-429.
59. Lakshika M., Caldera H.A. Knowledge Graphs Representation for Event-Related E-News Articles // *Machine Learning and Knowledge Extraction*. 2021. Т. 3. №. 4. pp. 802-818.
60. Bernasconi E., Ceriani M., Mecella M. Exploring a Text Corpus via a Knowledge Graph // *IRCDL*. 2021. pp. 91-102.
61. Богатырев М.Ю., Тухтин В.В. Построение концептуальных графов как элементов семантической разметки текстов // *Компьютерная лингвистика и интеллектуальные технологии: по материалам ежегодной Международной конференции «Диалог – 2009»*.
62. Logan R., Liu N.F., Peters M.E. et al. Barack’s Wife Hillary: Using Knowledge Graphs for Fact-Aware Language Modeling // *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. Italy: Association for Computational Linguistics. 2019. pp. 5962–5971.
63. Guu K., Lee K., Tung Z. et al. REALM: Retrieval Augmented Language Model Pre-Training // *arXiv preprint arXiv: 2002.08909*. URL: <https://arxiv.org/abs/2002.00388> (дата обращения: 24.09.2022).
64. Wang R., Tang D., Duan N. etc. K-Adapter: Infusing Knowledge into Pre-Trained Models with Adapters // *arXiv preprint arXiv:2002.01808*. <https://arxiv.org/abs/2002.01808> (дата обращения: 24.09.2022).
65. Yang B., Mitchell T. Leveraging Knowledge Bases in LSTMs for Improving Machine Reading // *arXiv preprint arXiv:1902.09091*. <https://arxiv.org/abs/1902.09091> (дата обращения: 24.09.2022).
66. He B., Zhou D., Xiao J. et al. Integrating Graph Contextualized Knowledge into Pre-trained Language Models // *arXiv preprint arXiv:1912.00147*. <https://arxiv.org/abs/1912.00147> (дата обращения: 24.09.2022).
67. Wang X., Gao T., Zhu Z. KEPLER: A Unified Model for Knowledge Embedding and Pre-trained Language Representation // *arXiv preprint arXiv:1911.06136*. <https://arxiv.org/abs/1911.06136> (дата обращения: 24.09.2022).
68. Weng J., Gao Y., Qiu J. et al. Construction and Application of Teaching System Based on Crowdsourcing Knowledge Graph // *Knowledge Graph and Semantic Computing: Knowledge Computing and Language Understanding: 4th China Conference (CKKS 2019)*. China. Singapore: Springer. 2019. pp. 25 – 37.
69. Harnoune A. et al. BERT based clinical knowledge extraction for biomedical knowledge graph construction and analysis // *Computer Methods and Programs in Biomedicine Update*. 2021. vol. 1. no. 100042.
70. Martínez-Rodríguez J.L., Hogan A., Lopez-Arevalo I. Information extraction meets the semantic web: a survey // *Semantic Web*. 2020. Т. 11. №. 2. pp. 255-335.
71. Баранов А.А. и др. Методы и средства комплексного интеллектуального анализа медицинских данных // *Труды Института системного анализа Российской академии наук*. 2015. Т. 65. №. 2. С. 81-93.
72. Васильев В.И. и др. Методика оценки актуальных угроз и уязвимостей на основе технологий когнитивного моделирования и Text Mining // *Системы управления, связи и безопасности*. 2021. №. 3. С. 110-134.

73. Васильев В.И., Вульфин А.М., Кучкарова Н.В. Автоматизация анализа уязвимостей программного обеспечения на основе технологии Text Mining // Вопросы кибербезопасности. 2020. №. 4 (38). С. 22-31.
74. Веб-сервис для хостинга IT-проектов и их совместной разработки. URL: <https://github.com/Koziev/rupostagger> (дата обращения: 26.09.2022).
75. Большакова Е.И., Воронцов К.В., Ефремова Н.Э., Клышинский Э.С., Лукашевич Н.В., Сапин А.С. Автоматическая обработка текстов на естественном языке и анализ данных // М.: Изд-во НИУ ВШЭ. 2017. с. 269.
76. De Marneffe M.C. et al. Universal Stanford dependencies: A cross-linguistic typology // Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14). 2014. pp. 4585-4592.
77. Простой граф знаний на текстовых данных. Хабр: Коллективный блог. URL: <https://habr.com/ru/post/559110/>. (дата обращения 08.07.2022).

Зулкарнеев Рустэм Халитович — д-р мед. наук, профессор, профессор, кафедра пропедевтики внутренних болезней с курсом физиотерапии, Башкирский государственный медицинский университет. Область научных интересов: исследования в области кардиореспираторной физиологии, пульмонологии, кардиологии, медицинской информатики. Число научных публикаций — 230. zrustem@ufanet.ru; улица Ленина, 3, 450000, Уфа, Россия; р.т.: +7(917)420-6925.

Юсупова Нафиса Исламовна — д-р техн. наук, профессор, профессор, кафедра вычислительной математики и кибернетики, Уфимский государственный авиационный технический университет. Область научных интересов: интеллектуальные методы обработки информации и управления с приложениями в социальных, экономических и технических системах. Число научных публикаций — 560. yussupova@ugatu.ac.ru; улица Карла Маркса, 12, 450000, Уфа, Россия; р.т.: +7(917)343-5953.

Сметанина Ольга Николаевна — д-р техн. наук, профессор, профессор, кафедра вычислительной математики и кибернетики, Уфимский государственный авиационный технический университет. Область научных интересов: интеллектуальные методы обработки информации и управления с приложениями в социальных, экономических и технических системах. Число научных публикаций — 250. smoljushka@mail.ru; улица Карла Маркса, 12, 450000, Уфа, Россия; р.т.: +7(917)755-2214.

Гаянова Майя Марсовна — канд. техн. наук, доцент, доцент, кафедра вычислительной математики и кибернетики, Уфимский государственный авиационный технический университет. Область научных интересов: интеллектуальные методы обработки информации и управления с приложениями в социальных, экономических и технических системах. Число научных публикаций — 100. mayagayanova@gmail.com; улица Карла Маркса, 12, 450000, Уфа, Россия; р.т.: +7(917)409-7014.

Вульфин Алексей Михайлович — канд. техн. наук, доцент, доцент, кафедра вычислительной техники и защиты информации, Уфимский государственный авиационный технический университет. Область научных интересов: исследования в области интеллектуального анализа данных и моделирования сложных технических систем. Число научных публикаций — 160. vulfin.am@ugatu.su; улица Карла Маркса, 12, 450000, Уфа, Россия; р.т.: +7(917)400-2189.

Поддержка исследований. Работа выполнена при финансовой поддержке РНФ (проект № 22-19-00471).

R. ZULKARNEEV, N. YUSUPOVA, O. SMETANINA, M. GAYANOVA, A. VULFIN
**METHOD AND MODELS OF EXTRACTION OF KNOWLEDGE
FROM MEDICAL DOCUMENTS**

Zulkarneev R., Yusupova N., Smetanina O., Gayanova M., Vulfin A. Method and Models of Extraction of Knowledge from Medical Documents.

Abstract. The paper analyzes the problem of extracting knowledge from clinical recommendations presented in the form of semi-structured corpora of text documents in natural language, taking into account their periodic updating. The considered methods of intellectual analysis of the accumulated arrays of medical data make it possible to automate a number of tasks aimed at improving the quality of medical care due to significant decision support in the treatment process. A brief review of well-known publications has been made, highlighting approaches to automating the construction of ontologies and knowledge graphs in the problems of semantic modeling of a problem-oriented text corpus. The structural and functional organization of the system of knowledge extraction and automatic construction of an ontology and a knowledge graph of a problem-oriented corpus for a specific subject area is presented. The main stages of knowledge extraction and dynamic updating of the knowledge graph are considered: named entity extraction, semantic annotation, term and keyword extraction, topic modeling, topic identification, and relationship extraction. The formalized representation of texts was obtained using a pre-trained BERT transformer model. The automatic selection of triplets "object" - "action" - "subject" based on part-of-speech markup of the text corpus was used to construct fragments of the knowledge graph. An experiment was carried out on a corpus of medical texts on a given topic (162 documents of depersonalized case histories of patients of a pediatric center) without preliminary markup in order to test the proposed solution for extracting triplets and constructing a knowledge graph based on them. An analysis of the experimental results confirms the need for a deeper markup of the corpus of text documents to take into account the specifics of medical text documents. For an unmarked corpus of texts, the proposed solution demonstrates satisfactory performance in view of the selection of atomic fragments included in the automatically generated ontology.

Keywords: clinical texts, information extraction, machine learning, medical data mining, automatic ontology building, knowledge graphs.

References

1. Baranov A.A. et al. [Technologies of complex intellectual analysis of clinical data]. *Vestnik Rossijskoj akademii medicinskih nauk - Bulletin of the Russian Academy of Medical Sciences*. 2016. vol. 71. №. 2. pp. 160-171. (In Russ.).
2. Musen M.A., Middleton B., Greenes R.A. Clinical decision-support systems. In: *Biomedical informatics*. Springer, 2014. pp. 643–674. doi: 10.1007/978-1-4471-4474-8_22.
3. Rencis E. Natural language-based knowledge extraction in healthcare domain. *Proceedings of the 2019 3rd International Conference on Information System and Data Mining*. 2019. pp. 138-142.
4. Bledzhjanc G.A., Sarkisjan M.A., Isakova Ju.A., Tumanov N.A., Popov A.N., Begmurodova N.Sh. Kljuचेvyе tehnologii formirovanija iskusstvennogo intellekta v medicine [Key technologies of artificial intelligence formation in medicine]. *Remedium*. 2015. № 12. pp.10–15. (In Russ.).
5. Rubrikator klinicheskikh rekomendacij [Rubricator of clinical recommendations]. Available at: https://cr.minzdrav.gov.ru/clin_recomend (accessed 01.10.2022). (In Russ.).

6. Dligach D., Bethard S., Becker L., Miller T.A., Savova G.K. Discovering body site and severity modifiers in clinical texts. *Journal of the American Medical Informatics Association (JAMIA)*. 2014. pp. 448–454. doi: 10.1136/amajnl-2013-001766.
7. Chikka V.R., Mariyasagayam N., Niwa Y., Karlapalem K. Information Extraction from Clinical Documents: Towards Disease/Disorder Template Filling. In: *Experimental IR Meets Multilinguality, Multimodality, and Interaction*. Springer. 2015. pp. 389–401. doi: 10.1007/978-3-319-24027-5_41.
8. Shelmanov A.O., Smirnov I.V., Vishneva E.A. Information extraction from clinical texts in Russian. *Computational Linguistics and Intellectual Technologies: Papers from the Annual International Conference Dialogue (2015)*. Issue 14 (21). 2015. pp. 560–572.
9. Kushnerova I.A., Akimov S.S. [Prospects for the use of artificial intelligence in medicine] *Komp'juternaja integracija proizvodstva i IPI-tehnologii*. Sb. nauchn. tr. VIII Vserossijskoj nauchn. -prakt. konf. [Computer integration of production and IPI technology]. Orenburg, 2017, pp. 249–250. (In Russ.).
10. Berestneva E.V., Sharopin K.A., Zharkova O.S. [Creating medical knowledge bases using decision trees]. *Uspеhi sovremennoj nauki – Successes of modern science*. 2016. № 10. pp. 69–72. (In Russ.).
11. Katsajov A.S., Ahatova Ch.F. [Hybrid neuro fuzzy data mining model for the formation of knowledge bases of soft expert diagnostic systems]. *Nauka i obrazovanie: nauchnoe izdanie MGTU im N.Je. Baumana – Science and Education: scientific publication of Bauman Moscow State Technical University*. 2012. № 12. pp. 34–43. (In Russ.).
12. Klimov A.A., Kuprijanovskij V.P., Grin'ko O.V., Pokusaev O.N. [On the issue of reverse engineering - the path from paper to digital ontological rules for educational technologies] *International Journal of Open Information Technologies*. 2019. vol. 7. № 9. pp. 82-91. (In Russ.).
13. Muromcev D., Volchek D., Romanov A. [Industrial knowledge graphs - the intellectual core of the digital economy]. *Control Engineering Rossija. - Control Engineering Russia*. 2019. № 5(83). pp. 32-39. (In Russ.).
14. Asim M.N., Wasim M., Ghani Khan M.U., Mahmood W., Abbasi H.M. A survey of ontology learning techniques and applications. *Database*. vol. 2018. Bay101. Available at: <https://doi.org/10.1093/database/bay101> (accessed 26.06.2022)
15. Al-Aswadi F.N., Chan H.Y., Gan K.H. Automatic ontology construction from text: a review from shallow to deep learning trend. *Artificial Intelligence Review*. 2020. vol. 53. №. 6. pp. 3901-3928.
16. Ding Y., Foo S. Ontology research and development. Part 1-a review of ontology generation. *Journal of information science*. 2002. vol. 28. №. 2. pp. 123-136.
17. Volchek D.G., Romanov A.A. [Creation and training of ontologies based on the analysis of the context and metadata of semi-structured content]. *Jekonomika: vchera, segodnja, zavtra - Economics: yesterday, today, tomorrow*. 2020. vol. 10. № 1A. pp. 303-312. doi: 10.34670/AR.2020.91.1.033 (In Russ.).
18. Huang H. et al. Core-Concept-Seeded LDA for Ontology Learning. *Procedia Computer Science*. 2021. vol. 192. pp. 222-231.
19. Minin A.S., Chuprina S.I. [Methods and tools for constructing ontologically controlled knowledge acquisition systems]. *Vestnik permskogo universiteta. Matematika. Mehanika. Informatika. - Perm university bulletin. Maths. Mechanics. Informatics*. 2021. №. 4 (55). pp. 25-34. (In Russ.).
20. Maksimov A.I., Molodov V.A., Runov S.S. [About one way of presenting knowledge in medical intelligent systems]. *Sovremennye innovacii – Modern innovations*. 2021. №1 (39). pp. 48–50. (In Russ.).

21. Kuleshov S.V., Zajceva A.A., Markov V.S. [Associative-ontological approach to natural language text processing]. *Intellektual'nye tehnologii na transporte – Intelligent technologies in transport*. 2015. № 4 (4). pp. 40–45. (In Russ.).
22. Mihajlov S.N., Malashenko O.I., Zajceva A.A. [Methodology of infological analysis of the semantic content of patients' appeals for the organization of electronic records]. *Trudy SPIIRAN – Works of SPIIRAN*. 2015. № 5 (42). pp. 140–154. (In Russ.).
23. Harnoune A. et al. BERT based clinical knowledge extraction for biomedical knowledge graph construction and analysis. *Computer Methods and Programs in Biomedicine Update*. 2021. vol. 1. no. 100042.
24. Ponkin D.I. [The concept of pre-trained language models in the context of knowledge engineering]. *International Journal of Open Information Technologies*. 2020. № 9. pp. 18–29. URL: <http://injoit.org/index.php/j1> (accessed: 24.09.2022). (In Russ.).
25. Zemljanskij S.A., Aksjonov S.V., Lyzin I.A., Berestneva O.G. [Thematic modeling in the context of medical texts]. *Doklady TUSUR – TUSUR reports*. 2021. vol. 24. № 4. pp. 58–64. (In Russ.).
26. Nugumanova A.B., Bajburin E.M., Mansurova M.E., Barahnin V.B. [Automatic extraction of concept lattices from medical texts based on a combination of formal concept analysis and bootstrapping technologies]. *Vestnik NGU. Serija: Informacionnye tehnologii – Bulletin of the NSU. Series: Information Technology*. 2018. vol. 16. № 4. pp. 140–152. (In Russ.).
27. Petroni F., Rocktaschel T., Lewis P. *Language Models as Knowledge Bases? Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP'2019)*. Hong Kong (China): Association for Computational Linguistics. 2019. pp. 2463–2473.
28. Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. arXiv preprint arXiv:1810.04805. URL: <https://arxiv.org/abs/1810.04805> (дата обращения: 24.09.2022).
29. Lee J., Yoon W., Kim D., Kim S., So C.H., Kang J. BioBERT: a pre-trained biomedical language representation model for biomedical text mining *Bioinformatics*. arXiv preprint arXiv: 1901.08746. URL: <https://arxiv.org/abs/1901.08746> (дата обращения: 24.09.2022).
30. Alsentzer E., Murphy J.R., Boag W., Weng W.-H., Jin D., Naumann T., McDermott M. Publicly available clinical bert embeddings. arXiv preprint arXiv:1904.03323. URL: <https://arxiv.org/pdf/1904.03323.pdf> (дата обращения: 24.09.2022).
31. Sboev A. et al. An analysis of full-size Russian complexly NER labelled corpus of Internet user reviews on the drugs based on deep learning and language neural nets. arXiv preprint arXiv:2105.00059. URL: <https://arxiv.org/pdf/2105.00059.pdf> (дата обращения: 24.09.2022).
32. Russian Drug Review corpus by Sag team (RDRS). URL: <https://sagteam.ru/med-corpus/stata/#ours-Pharm2021arxiv> (дата обращения: 24.09.2022).
33. Tutubalina E. et al. The Russian Drug Reaction Corpus and neural models for drug reactions and effectiveness detection in user reviews. *Bioinformatics*. 2021. vol. 37. № 2. pp. 243–249.
34. Aronson A.R., Lang F.M. An overview of MetaMap: historical perspective and recent advances // *Journal of the American Medical Informatics Association*. 2010. № 17 (3). pp. 229–236. doi:10.1136/jamia.2009.002733.
35. Schuyler P.L., Hole W.T, Tuttle M.S, Sherertz D.D. The UMLS Metathesaurus: representing different views of biomedical concepts. *Bulletin of the Medical Library Association*. 1993. № 81 (2). pp. 217–222.

36. Unified Medical Language System (UMLS). Available at: <http://www.nlm.nih.gov/research/umls/sourcereleasedocs/current/MSHRUS/> (accessed: 04.10.2022).
37. Gosudarstvennyj reestr lekarstvennyh sredstv [State Register of Medicines]. Available at: <http://grls.rosminzdrav.ru/Default.aspx> (accessed: 24.09.2022). (In Russ.).
38. Gusev P.Ju. [Text processing and preparation of vectorization models for the scientific text classification software package]. Modelirovanie, optimizacija i informacionnye tehnologii – Modeling, optimization and information technology. 2021. vol. 9. №1. pp. 6–7. (In Russ.).
39. Kelly L., Goeuriot L., Suominen H., Schreck T., Leroy G., Mowery D.L. et al. Overview of the SHARE/CLEF eHealth evaluation lab 2014. Springer. 2014. pp. 172–191. doi:10.1007/978-3-319-11382-1_17.
40. McCusker J.P., Erickson J.S., Chastain K., Rashid S., Weerawarana R., Bax M., McGuinness D.L. What is a knowledge graph? URL: <https://www.semantic-web-journal.net/> (дата обращения: 25.09.2022).
41. Aranovich Z.V. [Evolution of the concept and life cycle of knowledge graphs]. Sistemnaja informatika – System Informatics. 2020. №16. pp. 57–74. (In Russ.).
42. Färber M., Bartscherer F., Menne C., Rettinger A. Linked data quality of dbpedia, freebase, opencyc, wikidata, and yago. Semantic Web. 2016. pp. 1–53.
43. Huang Z., Yang J., Harmelen F.V., Hu Q. Constructing disease-centric knowledge graphs: a case study for depression (short version). Proceedings of the Conference on Artificial Intelligence in Medicine in Europe. Springer. 2017. pp. 48–52.
44. World Wide Web Consortium (W3C). URL: <https://www.w3.org/> (дата обращения: 25.09.2022).
45. Ehrlinger L., Wöß W. Towards a definition of knowledge graphs. SEMANTiCS (Posters, Demos, SuCESS). 2016. no. 48.
46. Ernst P., Siu A., Weikum G. KnowLife: a versatile approach for constructing a large knowledge graph for biomedical sciences. BMC bioinformatics. 2015. №16 (157). <https://doi.org/10.1186/s12859-015-0549-5>.
47. Stepanova D., Gad-Elrab M.H., Ho T.V. Rule Induction and Reasoning over Knowledge Graphs. Reasoning Web International Summer School. Springer, Cham. 2018. pp. 142-172.
48. Nickel M., Murphy K., Tresp V., Gabrilovich E. A review of relational machine learning for knowledge graphs. Proceedings of the IEEE, 104(1). 2016. vol. 104 (1). pp. 11–33.
49. Yao L., Mao C., Luo Y. KG-BERT: BERT for Knowledge Graph Completion. arXiv preprint arXiv: 1810.04805. URL: <https://arxiv.org/abs/1810.04805> (дата обращения: 24.09.2022).
50. Ji S., Pan S., Cambria E. et al. A Survey on Knowledge Graphs: Representation, Acquisition and Applications. arXiv preprint arXiv: 2002.00388. URL: <https://arxiv.org/abs/2002.00388> (дата обращения: 24.09.2022).
51. Yoo S.-Y., Jeong O.-K. Automating the expansion of a knowledge graph. Expert Systems with Applications. 2020. vol. 141. no. 112965.
52. Global and Unified Access to Knowledge Graphs. Available at: <https://www.dbpedia.org/> (accessed 07.07.2022).
53. Википедия. Свободная энциклопедия. [Wikipedia. The Free Encyclopedia]. Available at: www.en.wikipedia.org/wiki/Main_Page (accessed 08.07.2022). (In Russ.).
54. Adams T. Google and the future of search: Amit Singhal and the knowledge graph. The Guardian. 2013. vol. 19.
55. Ehrlinger L., Wöß W. Towards a definition of knowledge graphs. SEMANTiCS (Posters, Demos, SuCESS). 2016. vol. 48. №. 1-4. p. 2.

56. Silva M.C., Faria D., Pesquita C. Matching Multiple Ontologies to Build a Knowledge Graph for Personalized Medicine. *European Semantic Web Conference*. Springer, Cham. 2022. pp. 461-477.
57. Kumar K., Manocha S. Constructing knowledge graph from unstructured text. *Self*. 2015. vol. 3. p. 4.
58. Grainger T. et al. The Semantic Knowledge Graph: A compact, auto-generated model for real-time traversal and ranking of any relationship within a domain. *2016 IEEE international conference on data science and advanced analytics (DSAA)*. IEEE. 2016. pp. 420-429.
59. Lakshika M., Caldera H.A. Knowledge Graphs Representation for Event-Related E-News Articles. *Machine Learning and Knowledge Extraction*. 2021. vol. 3. №. 4. pp. 802-818.
60. Bernasconi E., Ceriani M., Mecella M. Exploring a Text Corpus via a Knowledge Graph. *IRCDL*. 2021. pp. 91-102.
61. Bogatyrev M.Ju., Tjuhtin V.V. [Construction of conceptual graphs as elements of semantic markup of texts. *Computational Linguistics and Intelligent Technologies*]. Po materialam. ezhegodnoj Mezhdunarodnoj konferencii «Dialog – 2009». [By materials. annual International Conference "Dialogue - 2009"]. (In Russ.).
62. Logan R., Liu N.F., Peters M.E. et al. Barack's Wife Hillary: Using Knowledge Graphs for Fact-Aware Language Modeling. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. Italy: Association for Computational Linguistics. 2019. pp. 5962–5971.
63. Guu K., Lee K., Tung Z. et al. REALM: Retrieval Augmented Language Model Pre-Training. *arXiv preprint arXiv: 2002.08909*. URL: <https://arxiv.org/abs/2002.00388> (дата обращения: 24.09.2022).
64. Wang R., Tang D., Duan N. etc. K-Adapter: Infusing Knowledge into Pre-Trained Models with Adapters. *arXiv preprint arXiv:2002.01808*. <https://arxiv.org/abs/2002.01808> (дата обращения: 24.09.2022).
65. Yang B., Mitchell T. Leveraging Knowledge Bases in LSTMs for Improving Machine Reading. *arXiv preprint arXiv:1902.09091*. <https://arxiv.org/abs/1902.09091> (дата обращения: 24.09.2022).
66. He B., Zhou D., Xiao J. et al. Integrating Graph Contextualized Knowledge into Pre-trained Language Models. *arXiv preprint arXiv:1912.00147*. <https://arxiv.org/abs/1912.00147> (дата обращения: 24.09.2022).
67. Wang X., Gao T., Zhu Z. KEPLER: A Unified Model for Knowledge Embedding and Pre-trained Language Representation. *arXiv preprint arXiv:1911.06136*. <https://arxiv.org/abs/1911.06136> (дата обращения: 24.09.2022).
68. Weng J., Gao Y., Qiu J. et al. Construction and Application of Teaching System Based on Crowdsourcing Knowledge Graph. *Knowledge Graph and Semantic Computing: Knowledge Computing and Language Understanding: 4th China Conference (CKKS 2019)*. China. Singapore: Springer. 2019. pp. 25 – 37.
69. Harnoun A. et al. BERT based clinical knowledge extraction for biomedical knowledge graph construction and analysis. *Computer Methods and Programs in Biomedicine Update*. 2021. vol. 1. no. 100042.
70. Martínez-Rodríguez J.L., Hogan A., Lopez-Arevalo I. Information extraction meets the semantic web: a survey. *Semantic Web*. 2020. vol. 11. №. 2. pp. 255-335.
71. Baranov A.A. et al. [Methods and means of complex intellectual analysis of medical data.] *Trudy Instituta sistemnogo analiza Rossijskoj akademii nauk*. 2015. vol. 65. №. 2. pp. 81-93. (In Russ.).
72. Vasil'ev V.I. et al. [Methodology for assessing current threats and vulnerabilities based on cognitive modeling and Text Mining technologies]. *Sistemy upravlenija, svjazi i bezopasnosti. – Control, communication and security systems*. 2021. №. 3. pp. 110-134. (In Russ.).

73. Vasil'ev V.I., Vul'fin A.M., Kuchkarova N.V. [Automation of software vulnerability analysis based on Text Mining technology]. Voprosy kiberbezopasnosti. - Cyber security issues. 2020. № 4 (38). pp. 22-31. (In Russ.).
74. Veb-servis dlja hostinga IT-proektov i ih sovmestnoj razrabotki [A web service for hosting IT projects and their joint development]. Available at: <https://github.com/Koziev/rupostagger> (In Russ.).
75. Bol'shakova E.I., Voroncov K.V., Efremova N.Je., Klyshinskij Je.S., Lukashevich N.V., Sapin A.S. Avtomaticheskaja obrabotka tekstov na estestvennom jazyke i analiz dannyh [Automatic natural language text processing and data analysis]. Moscow: HSE Publishing House. 2017. p. 269 (In Russ.).
76. De Marneffe M.C. et al. Universal Stanford dependencies: A cross-linguistic typology. Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14). 2014. pp. 4585-4592.
77. Prostoj graf znaniy na tekstovyh dannyh. Habr: Kollektivnyj blog. [A simple knowledge graph on textual data. Habr: Collective blog]. Available at: <https://habr.com/ru/post/559110/>. (accessed 08.07.2022). (In Russ.).

Zulkarneev Rustem — Ph.D., Dr.Sci., Professor, Professor, Department of propaedeutics of internal diseases with a course of physiotherapy, Bashkir State Medical University. Research interests: research in the field of cardiorespiratory physiology, pulmonology, cardiology, medical informatics. The number of publications — 230. zrustem@ufanet.ru; 3, Lenina St., 450000, Ufa, Russia; office phone: +7(917)420-6925.

Yusupova Nafisa — Ph.D., Dr.Sci., Professor, Professor, Department of computational mathematics and cybernetics, Ufa State Aviation Technical University. Research interests: intelligent methods of information processing and management with applications in social, economic and technical systems. The number of publications — 560. yussupova@ugatu.ac.ru; 12, Karl Marx St., 450000, Ufa, Russia; office phone: +7(917)343-5953.

Smetanina Olga — Ph.D., Dr.Sci., Professor, Professor, Department of computational mathematics and cybernetics, Ufa State Aviation Technical University. Research interests: intelligent methods of information processing and management with applications in social, economic and technical systems. The number of publications — 250. smoljushka@mail.ru; 12, Karl Marx St., 450000, Ufa, Russia; office phone: +7(917)755-2214.

Gayanova Maya — Ph.D., Associate Professor, Associate professor, Department of computational mathematics and cybernetics, Ufa State Aviation Technical University. Research interests: intelligent methods of information processing and management with applications in social, economic and technical systems. The number of publications — 100. maya.gayanova@gmail.com; 12, Karl Marx St., 450000, Ufa, Russia; office phone: +7(917)409-7014.

Vulfin Alexey — Ph.D., Associate Professor, Associate professor, Department of computer science and information protection, Ufa State Aviation Technical University. Research interests: research in the field of data mining and modeling of complex technical systems. The number of publications — 160. vulfin.am@ugatu.su; 12, Karl Marx St., 450000, Ufa, Russia; office phone: +7(917)400-2189.

Acknowledgements. This work was supported by the Russian Science Foundation (project no. 22-19-00471).

Д.Л. Зайцев, В.М. Брыксин, К.С. Белотелов, Ю.И. Компаниец,
Р.Н. Яковлев

АЛГОРИТМЫ И ИЗМЕРИТЕЛЬНЫЙ КОМПЛЕКС КЛАССИФИКАЦИИ ИСТОЧНИКОВ СЕЙСМИЧЕСКИХ СИГНАЛОВ, ОПРЕДЕЛЕНИЯ РАССТОЯНИЯ И АЗИМУТА ДО ПУНКТА ВОЗБУЖДЕНИЯ ПОВЕРХНОСТНЫХ ВОЛН

Зайцев Д.Л., Брыксин В.М., Белотелов К.С., Компаниец Ю.И., Яковлев Р.Н. Алгоритмы и измерительный комплекс классификации источников сейсмических сигналов, определения расстояния и азимута до пункта возбуждения поверхностных волн.

Аннотация. Методы машинного обучения и цифровой обработки сигналов применяются в различных отраслях, в том числе при анализе и классификации сейсмических сигналов поверхностных источников. Разработанный алгоритм анализа типов волн позволяет автоматически идентифицировать и, соответственно, отделять приходящие сейсмические волны на основе их характеристик. Для выделения типов волн используется сейсмический измерительный комплекс, определяющий характеристики граничных волн поверхностных источников с использованием специальных молекулярно-электронных датчиков угловых и линейных колебаний. Представлены результаты работы алгоритма обработки данных, получаемых по методике сейсмических наблюдений, использующей спектральный анализ на основе вейвлета Морле. Также в работе описан алгоритм классификации источников сигнала, определения расстояния и азимута до пункта возбуждения поверхностных волн, рассмотрено использование статистических характеристик и MFCC (Мел-частотные кепстральные коэффициенты) параметров, а также их совместное применение. При этом в качестве статистических характеристик сигнала были использованы следующие: дисперсия, коэффициент эксцесса, энтропия и среднее значение, а в качестве метода машинного обучения был выбран градиентный бустинг; в качестве метода определения расстояния до источника сигнала применен метод машинного обучения на основе градиентного бустинга с применением статистических и MFCC параметров. Обучение проводилось на тестовых данных на основе выделенных особенных параметрах сигналов источников сейсмического возбуждения поверхностных волн. С практической точки зрения, новые методы сейсмических наблюдений и анализа граничных волн позволяют решить проблему обеспечения плотной расстановки датчиков в труднодоступных местах, устранить недостаток знаний в алгоритмах обработки данных сейсмических сенсоров угловых движений, выполнить классификацию и систематизацию источников, повысить точность прогнозирования, реализовать алгоритмы локации и сопровождения источников. Целью работы стало создание алгоритмов обработки сейсмических данных для классификации источников сигнала, определения расстояния и азимута до пункта возбуждения поверхностных волн.

Ключевые слова: граничные волны, молекулярная электроника, вейвлет анализ, машинное обучение, определение азимута, определение расстояния, алгоритм обработки данных.

1. Введение. В последние годы много внимания уделяется достижениям в области вращательной сейсмологии [1]. Большинство исследователей сходятся во мнении, что природа, свойства, прогнозные модели и классификация поверхностных источников

сейсмического сигнала могут и должны изучаться за счет всестороннего анализа и расширения моделей распространения поверхностных волн. В работе [2] было показано, что возможно рассчитать дисперсионные кривые для волн Лява, используя амплитудные соотношения для поперечного ускорения и вертикальной скорости вращения, при условии достаточно высокого соотношения сигнал/шум в записанных сигналах. В работе [3] показывается, что с помощью теоретических соотношений между линейными и вращательными движениями для волн Рэлея и Лява в приповерхностной среде, можно получить направление распространения волн, а также фазовые и волновые скорости, используя только одну станцию. Это обстоятельство становится особенно актуально в труднодоступных местах, где сложно обеспечить плотную расстановку датчиков. В тоже время одновременное измерение параметров волнового поля и их пространственных градиентов в одной точке приема позволяет эффективно повысить разрешение. Так, например, в исследовании [4] показано, что, явно используя записи с вращательных датчиков, и пользуясь вычисленным потоком энергии и преобразованием Хоффа можно улучшить точность локализации сигнала. В работе [5] были разработаны фильтры на основе пространственного градиента, позволяющие разделить приходящие волны на восходящие/нисходящие и на P/S составляющие. В работе [6] были предложены 6-компонентные поляризационные модели для всех типов волн, и был предложен алгоритм, который позволяет автоматически идентифицировать и, соответственно, разделять приходящие волны на основе их поляризационных характеристик. Для выделения типов волн часто используется алгоритм MUSIC (Multiple Signal Classification). Этот алгоритм был разработан для получения спектра зашумленного сигнала на основе разбиения его на пространство сигнала и пространство шумов, с помощью матрицы когерентности [7]. Для решения задач с помощью таких алгоритмов вычисляют собственные значения и собственные вектора матрицы. Ненулевым собственным значениям соответствуют реальные сигналы, затем подбираются наиболее подходящие поляризационные параметры и, исходя из этого, определяются тип волны, а также ее характеристики.

Изучение поверхностных сейсмических эффектов особенно широко применяется в области мониторинга зданий и сооружений, которые вызывают появление поверхностных сейсмических волн благодаря ветру, оседанию конструкций, сдвиговым движениям почвы и так далее. Благодаря взаимодействию грунт-структура здание преобразует энергию падающей волны (например, ветра) во

вращательные движения фундамента и окружающего грунта. Таким образом, здание выступает в качестве источника вращательных поверхностных волн. В густонаселенных мегаполисах, где расстояние между соседними зданиями невелико, происходит взаимодействие здания с грунтом и обратно. В таком случае, а также в случае, длинных мостов с несколькими опорами, требуется детальный двух- и трехмерный анализ для описания сложной генерации вращательного отклика и вращений в грунте [8]. Натурные эксперименты по взаимодействию грунта и сооружений дали данные для измерения и количественной оценки характера вращательных движений на границе раздела грунта и фундаментов зданий. Однако при отсутствии зарегистрированных сильных вращательных движений в ближнем поле инженерные исследования должны использовать численное моделирование для оценки и расчета вклада вращательных движений в отклик сооружений. Например, в [9] показано, что спектральные амплитуды псевдо-относительной скорости возбуждения горизонтальными, вертикальными и вращательными движениями грунта могут быть представлены суперпозицией трех математических величин. Этот новый результат подчеркивает важность вращательного возбуждения грунта и необходимость включения его в оценки отклика при проектировании очень высоких зданий [10]. В другом исследовании [11] численными методами моделируется распространение сейсмических волн через структуру и деформации ее элементов за пределами линейного диапазона отклика. Продемонстрировано как создание зон нелинейного отклика и их локализация («пластические шарниры») приводят к возникновению зон больших локальных вращений. Размещением на балках и колоннах малоапертурных матриц преобразователей вращения было продемонстрировано, достижение нового уровня разрешения точечных деформаций, благодаря тому, что с близко расположенных датчиков вращения можно регистрировать кривизну в заданной точке [12]. Таким образом, массовые измерения вращательных движений в важных конструкциях позволяют надежно отслеживать состояние конструкций в режиме реального времени.

Другим значимым направлением, широко освещенным в литературе последнего времени, по теме поверхностных источников, их классификации и изучения являются системы обнаружения нарушителей для нужд систем охраны и пр. В частности, во многих исследованиях обсуждается задача определения направления на объект, являющийся источником поверхностных сейсмических возмущений. Традиционное решение этой задачи заключается в

использовании в качестве источника исходных данных сигналов вертикальных сейсмоприемников. Определение координат источника происходит путем изучения данных с нескольких разнесенных в пространстве датчиков, регистрирующих изучаемое сейсмическое возмущение. При этом приемники располагаются по заданной схеме, например по периметру или зигзагом [13]. Алгоритмы выявления азимута источника сейсмосигнала, как правило, строятся на определении задержки времени достижения сейсмического сигнала приемников. Для более точного определения направления на сейсмический источник поверхностных волн применяют увеличение частоты опроса при анализе [14].

Перспективной приборной базой для регистрации граничных сейсмических волн от поверхностных источников являются электрохимические датчики угловых колебаний. Интерес к практическому использованию сейсмических датчиков угловых колебаний в физике значительно вырос в последние 10 лет благодаря теоретическим и экспериментальным исследованиям [15–17]. В указанных работах обсуждаются новые возможности для геофизических исследований, которые открываются благодаря применению датчиков угловых колебаний. В частности, можно считать экспериментально установленным факт, что использование датчиков угловых колебаний позволяет эффективно определять градиент сейсмического поля и за счет этого сокращать количество точек наблюдения при сохранении качества данных [18], а также исключать пространственный алиасинг при недостаточной плотности расстановки.

Перспективы молекулярно-электронных датчиков вращательных движений и линейного вертикального датчика для анализа источников поверхностных волн для примера охранных систем показаны в работе [19]. В данной работе демонстрируется принципиально отличный от существующих подход в измерении направления на поверхностный источник сейсмических возмущений. Для решения задачи используется один многокомпонентный сейсмический модуль, все измерительные компоненты которого сосредоточены в одном корпусе. Определение направления при таком подходе основывается не на измерении разности времен прихода волны на разнесённые датчики, а на сопоставлении амплитуд и фаз сигналов на разных компонентах одного модуля. При этом нет необходимости увеличивать частоту дискретизации сигнала при обработке. В результате энергопотребление такой системы, а следовательно, и автономность её работы оказываются ниже, чем у

традиционных разнесенных систем аналогичного назначения. В работах [20, 21] показана возможность совместного использования датчиков линейных и угловых колебаний для повышения точности определения положения источников сигналов при микросейсмических исследованиях. В работах [22–24] экспериментально показано селективно более высокая чувствительность датчиков угловых колебаний по отношению к волнам, распространяющимся вдоль границ. Обозначенное свойство использовалось для фильтрации поверхностных волн, которые рассматривались как шумы измерений. В настоящей работе граничные волны являются целевыми, и селективность датчиков угловых движений к волнам такого типа является средством увеличения соотношения сигнал/шум для измерения параметров этих волн.

Датчики угловых колебаний активно встречаются и в патентных исследованиях. В частности, способность датчиков угловых колебаний проводить разделение продольных и поперечных волн в сейсмическом сигнале, а также провести дифференциацию между различными видами интерфейсных волн, в зависимости от характера их поляризации (ориентация эллипса поляризации и степень эллиптичности) используется в патентах [25–27], выданных и поддерживаемых Шлюмберже. Отметим, что большинство полевых исследований, выполнено с применением электрохимических датчиков угловых колебаний, на основе молекулярно-электронной технологии. Среди последних исследований параметров измерителей угловых волновых полей можно отметить работы [28, 29], в которых подробно исследуются механизмы собственных шумов чувствительных элементов. В то же время, как было сказано ранее, совместное использование низкочастотных датчиков линейных и угловых движений позволяет получить наиболее полную картину волнового поля возмущений поверхностных источников сигнала. В этом аспекте интересно проследить за последними достижениями в области разработки молекулярно-электронных датчиков линейных движений, отличающихся крайне высокой чувствительностью (при схожих габаритах), которые отражены в публикациях [30–34]. В целом, несмотря на успехи в развитии измерительной аппаратуры, алгоритмы обработки данных в настоящее время еще недостаточно проработаны, и в предлагаемой работе авторы исправляют указанный недостаток.

Таким образом, основными целями работы стали: разработка алгоритмов обработки данных, получаемых по методике сейсмических наблюдений с использованием датчиков для регистрации угловых и линейных колебаний в сейсмическом волновом поле поверхностных

источников, для классификации источников сигнала, определения расстояния и азимута до пункта возбуждения поверхностных волн; разработка измерительного комплекса для проведения экспериментальных исследований сейсмических событий на основе измерения характеристик граничных волн поверхностных источников с использованием специальных видов датчиков – молекулярно-электронных датчиков угловых и линейных колебаний, характеризующихся селективной способностью регистрировать сдвиговую компоненту волнового поля с высокой чувствительностью.

Применение новой технологии сейсмических наблюдений поверхностных источников возбуждений на граничных волнах с использованием электрохимических сейсмических датчиков угловых колебаний, позволяющей принципиально повысить качество и информативность данных, обуславливает новизну предлагаемого исследования. Впервые в работе применяются датчики такого типа для регистрации и детального изучения граничных сейсмических волн от поверхностных источников сигнала. Возможность прямой регистрации крайне малых угловых колебаний грунта в широком частотном и динамическом диапазонах позволила разработать новые, потенциально более эффективные методы проведения сейсмических измерений и обработки полученных данных, и прежде всего, при исследовании сигналов, созданных поверхностными источниками.

Непосредственным конкурентом исследованию можно рассматривать работы [35–37]. Так в [35], например, предложен альтернативный механизм оценки источника сигнала и скоростей распространения возмущений. Авторами применяется мультипликативный метод визуализации с обращением времени, основанный на несвязанных волновых полях. Условие мультипликативного отображения с обращением времени применяется к автоматическим и перекрестным корреляциям несвязанных волновых полей каждого приемника для построения окончательного изображения местоположения. Продемонстрировано, что численные эксперименты могут давать надежные изображения местоположения источника с четкой диаграммой направленности высокого разрешения. В [36] проиллюстрирована сейсмологическая ценность данных о вращательном движении грунта, на примере телесеизмического землетрясения, зарегистрированного на многокомпонентной кольцевой лазерной обсерватории. Продемонстрировано то, как параметры волн (фазовая скорость, направление распространения и угол эллиптичности) и типы волн нескольких фаз могут быть автоматически оценены. В [37] сейсмическая была детально

проанализирована волна Релея с точки зрения параметров, определяющих форму ее математической записи, основанной на сходстве с записями, полученными во время вызванной сейсмичности при мониторинге ближнего поля шестикомпонентных измерений. При этом проведенные полевые измерения позволили соотнести количество излучаемой сейсмической энергии с ожидаемой наибольшей амплитудой вращательных колебаний во всем поле их воздействия. Это, в свою очередь, позволяет прогнозировать, согласно математической модели, расстояние до источника волн и их энергию.

2. Экспериментальная установка. Прототип измерительного комплекса для регистрации граничных сейсмических волн на основе молекулярно-электронных датчиков угловых и линейных колебаний состоит из сейсмического измерительного модуля, на основе 3 угловых и 3 линейных датчиков, помещенных в один корпус, автономной 6 канальной 24-битной системы сбора данных NDAS-8226 [38] и системы соединительных проводов (рисунок 1). При этом питание системы может осуществляться как от аккумуляторной батареи, так и от стационарного источника питания. Количество каналов позволяет вести одновременную запись всех бти компонент. Система оснащена высокоточным кварцевым генератором с привязкой к абсолютному времени с помощью GPS/GLONASS, что позволяет обеспечить точность синхронизации выше, чем стандартная погрешность по времени в 1 мкс. В таблице 1 приведены основные характеристики прототипа сейсмического измерительного комплекса.




Рис. 1. Прототип измерительного комплекса для регистрации граничных сейсмических волн на основе датчиков угловых и линейных колебаний. Состоит из системы сбора данных NDAS-8226 – 1 и сейсмического измерительного модуля – 2

Таблица 1. Основные характеристики прототипа измерительного модуля

Наименование характеристики	Значение для линейных компонент	Значение для угловых компонент
Рабочий частотный диапазон по уровню на границах -3 дБ	1-300 Гц	1-150 Гц
Коэффициент чувствительности	250 В/м/с	50 В/рад/с
Неравномерность в рабочем частотном диапазоне	+1 дБ	+1 дБ
Номинальное энергопотребление на компоненту	15 мА	15 мА
Уровень собственных шумов	-100 дБ, -120 дБ (<10 Гц)	-100 дБ, -120 дБ (<10 Гц)

При проведении эксперимента предварительно размеченном поле были проведены записи сигнала с проходом человека по определенным траекториям. Выбранные расстояния не специфичны и были установлены таковыми, исходя из возможностей экспериментальной площадки. Вместе с тем выбранные размеры полигона неплохо соответствуют приемлемым расстояниям достаточной чувствительности применяемых сенсоров для исследуемых задач. Полигон представлял собой плотный грунт, испытал (пешеход массой 70 кг) совершал движение по заданным траекториям со скоростью 4-6 км/ч. Контрольные точки и траектории движения для экспериментов были заранее размечены. В контрольных точках, обозначенных на рисунке окружностями, испытал совершает прыжок, данное действие позволяет проконтролировать этапы выполнения эксперимента. Данный набор экспериментов был выбран с целью получения обширного набора азимутов и расстояний до измерительного модуля.

Схемы экспериментов изображены на рисунках 2–4 с указанием принятых для дальнейшего описания обозначений.

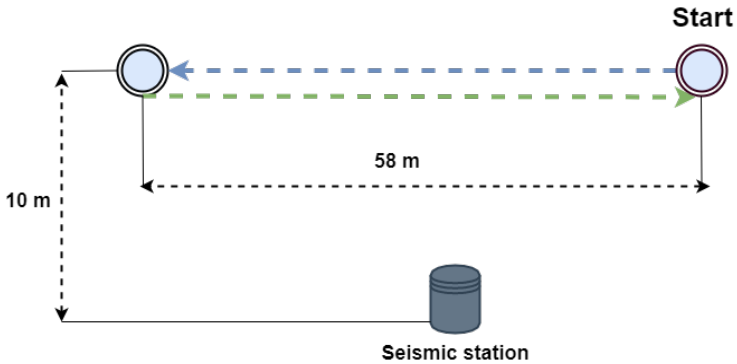


Рис. 2. Схема прохода для экспериментов А и В. Испытатель проходит по линии вдоль измерительного модуля. В эксперименте А испытатель от точки старта, а в эксперименте В к точке старта. Расстояние между точками – 58 метров, расстояние между измерительным модулем и траекторией движения – 10 метров




Рис. 3. Схема прохода для эксперимента С. Испытатель проходит из стартовой точки к вершине квадрата 16 метров и далее начинает движение по квадрату со стороной 20 метров, и возвращается к точке старта. Измерительный модуль находится в центре квадрата




Рис. 4. Схема прохода для эксперимента D. Испытатель движется по треугольнику, на одной из сторон которого находится измерительный модуль. Стороны треугольника равны 30, 36 и 40 метров

3. Обработка результатов. Для анализа данных, полученных с датчиков для регистрации угловых и линейных колебаний в сейсмическом волновом поле поверхностных источников необходима их предварительная фильтрация. Важно выбрать оптимальный частотный диапазон, так как исходный сигнал содержит значительную долю шумов от различных источников (рисунок 5).

Сигналы с рассматриваемых источников не стационарны по своей природе, поэтому распространенный метод преобразования сигнала Фурье здесь не целесообразен, так как преобразование Фурье имеет высокое разрешение в частотной области, однако нулевое во временной. Для подобных задач используется Вейвлет преобразование, поскольку оно обладает всеми преимуществами преобразования Фурье, и при этом Вейвлетные базисы могут быть хорошо локализованными как по частоте, так и по времени.

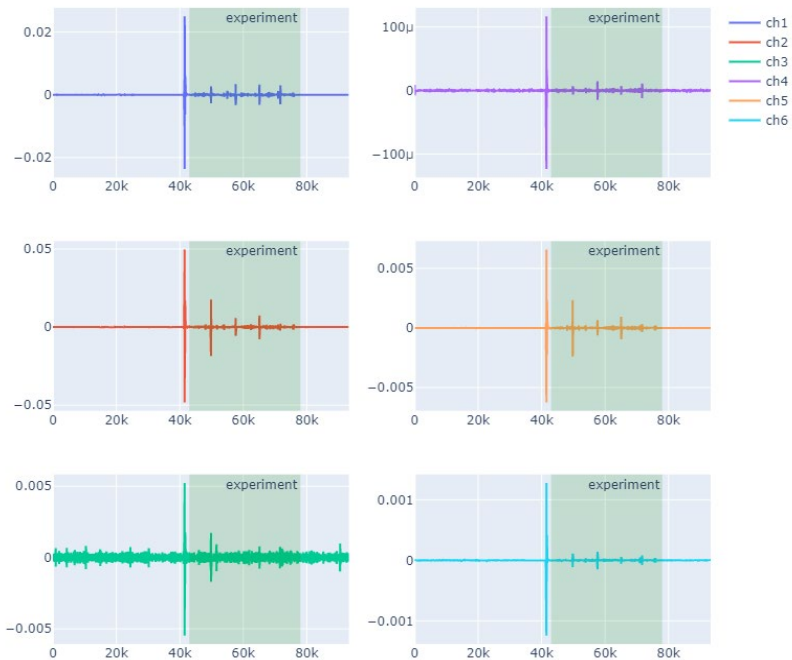


Рис. 5. Пример записи со всех компонент для одного эксперимента. На каждом из 6 графиков представлен сигнал с отдельной компоненты. По оси X – отсчеты АЦП (частота опроса – 500 Гц). По оси Y - амплитуда сигнала в вольтах

В качестве материнского вейвлета был применен вейвлет Морле (рисунок 6). Вейвлет Морле впервые был введен французским геофизиком Жаном Морле в 1984 году. Данный вейвлет широко применяется для геофизических задач [39]. Задается уравнением (1):

$$\psi(r) = \exp\left(ikr - \frac{r^2}{2}\right). \quad (1)$$

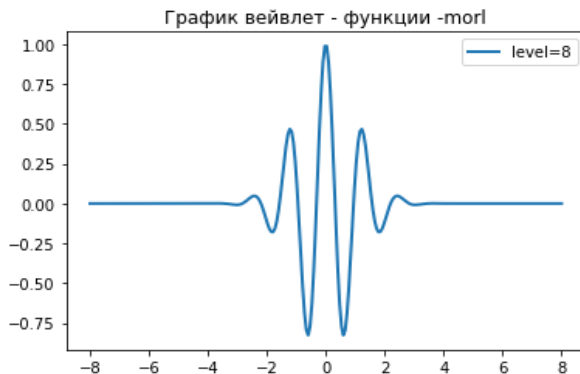


Рис. 6. График вейвлет функции Морле, по оси x – время, по оси y – амплитуда




Рис. 7. Спектрограмма сигнала на основе вейвлета Морле. Полезный сигнал находится в диапазоне 10 - 35 Гц, для наглядности изображена спектрограмма до 100 Гц. По оси x – время в секундах, по оси y – частота, Гц

С помощью спектрального анализа, на основе вейвлета Морле, представленного на рисунке 7, было установлено, что наибольшая плотность сигнала в экспериментах находится в области от 10 до 35 Гц.

На основании проведенного анализа был выбран фильтр Баттерворта второго порядка с частотами среза 10 и 35 Гц, так как данный фильтр достаточно простой и позволяет отсечь лишние шумовые сигналы. Сигналы со всех датчиков были пропущены через данный фильтр, результат фильтрации одной из записей представлен на рисунке 8.

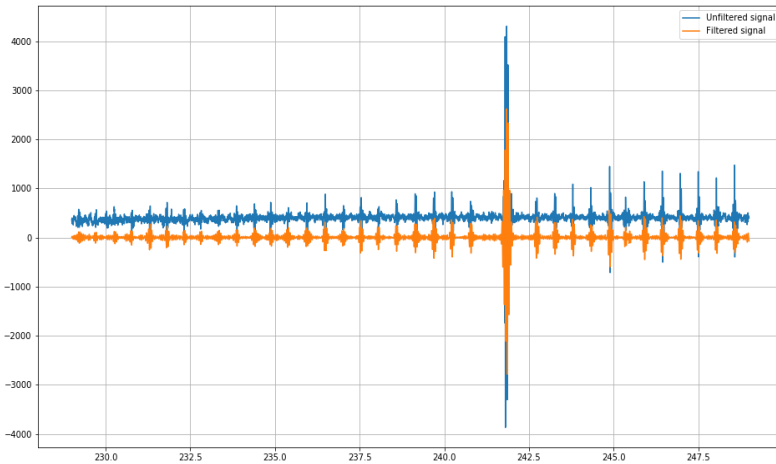


Рис. 8. Сравнение фильтрованного и нефильтрованного сигнала аналогового датчика. По оси x – время в секундах, по оси y – амплитуда в мкВ

Для классификации наличия/отсутствия источника полезного сигнала, были рассмотрены несколько подходов: использование статистических характеристик и MFCC (Мел-частотные кедральные коэффициенты) параметров [40], а также их совместное применение.

Мел – нелинейная шкала частот, основанная на восприятии высоты звука человеком, мел частоты (m) связана с герцем [41] следующим образом (формула 2):

$$m = 2595 \log_{10} \left(1 + \frac{f}{700} \right) = 1127 \ln(1 + f/700). \quad (2)$$

Кедр – функция обратного преобразования Фурье от логарифма спектра мощности сигнала [42]. Кедр можно записать следующим выражением:

$$C_S(q) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \ln \ln |S(\omega)|^2 e^{i\omega q} d\omega, \quad (3)$$

где $S(\omega)$ – спектр входного сигнала.

MFCC параметры были выбраны, поскольку широко применяются при анализе акустических сигналов, например в [43], проводились исследования, где они использовались с сейсмическими данными [44]. Преимущества их применения к текущей задаче состоит в том, что Мел-частотные кедральные коэффициенты имеют

большее разрешение в низкочастотной области, чем обычные спектральные характеристики. Было использовано по 40 коэффициентов кепстра с каждого сенсора. В качестве статистических характеристик сигнала были использованы следующие: дисперсия, коэффициент эксцесса, энтропия и среднее значение.

Данные были предварительно размечены на участки, содержащие и не содержащие полезный сигнал (рисунок 9). Далее с помощью этих данных была проведена бинарная классификация методом машинного обучения. В качестве метода машинного обучения был выбран градиентный бустинг [45], так как этот алгоритм подходит для нелинейных данных и устойчив к переобучению.




Рис. 9. Результат ручной разметки сигнала. Синим цветом представлен сигнал с датчика, красным цветом выделен человеческий шаг. По оси X – отсчеты АЦП (частота опроса АЦП - 500 Гц). По оси Y – амплитуда сигнала в вольтах

Для каждого отрезка с сигналом были вычислены различные статистические параметры: средняя амплитуда на отрезке, дисперсия, куртозис, энтропия. Кроме того, были извлечены MFCC параметры.

MFCC параметры используются при анализе акустических и сейсмических сигналов [44, 46]. MFCC параметры имеют большее разрешение в низкочастотной области, чем обычные спектральные характеристики.

Для каждого типа сигнала были взяты участки с искомым сигналом и участки с шумом и переданы на обучение моделей в случайном порядке, задача моделирования заключалась в определении, является ли данный сигнал полезным. Так как суммарное количество всех параметров для всех каналов было велико и составило 270 коэффициентов, было решено провести предварительный отбор на основе корреляции с зависимой переменной. Для каждой задачи число параметров оценивалось на основе таблицы корреляций. В целом на

вход модели поступали параметры с корреляцией не ниже 0.2 (рисунок 10).




Рис. 10. График корреляций для записей с проходом человека. По оси X – полученные параметры, по оси Y – зависимая бинарная переменная сигнал/шум. Цветом отражена сила корреляции, а цифры в каждом столбце являются значением корреляции с зависимой переменной

Ниже приведена сравнительная таблица результатов обучения модели классификации при помощи описанных параметров, где STAT – статистические характеристики. В качестве метрики валидации была выбрана метрика ROC-AUC (Receiver Operator Characteristic- Area Under Curve) [47], при которой максимальный результат достигается при 1.

ROC-кривая – кривая, которая показывает зависимость количества верно классифицированных положительных результатов от количества неверно классифицированных отрицательных результатов. AUC – площадь, ограниченная ROC-кривой и осью доли ложных положительных классификаций, при этом чем выше показатель AUC, тем качественнее классификатор, значение 0,5 демонстрирует непригодность выбранного метода классификации (соответствует случайному результату).

В таблице 2 приведены сравнительные результаты обработки.

Из таблицы 2 видно, что наилучший результат, при классификации наличия источников сигнала, достигается путем совместного применения статистических и MFCC параметров. При небольшом отдалении от сенсора, предположительно до 25 метров, достаточно использовать только статистические характеристики.

Таблица 2. Точность классификации сигнала, метрика ROC-AUC

	Эксперимент А (максимальное удаление от сенсоров 34 м)	Эксперимент В (максимальное удаление от сенсоров 34 м)	Эксперимент С (максимальное удаление от сенсоров 28 м)	Эксперимент D (максимальное удаление от сенсоров 28 м)
STAT	0.905	0.874	0.934	0.969
MFCC	0.941	0.919	0.942	0.984
STAT + MFCC	0.946	0.932	0.958	0.986

Для определения расстояния до источника на основе данных, полученных с датчиков для регистрации угловых и линейных колебаний, был разработан алгоритм классификации наличия полезного сигнала, расстояния и направления до источника его возбуждения, представленный на рисунке 11.

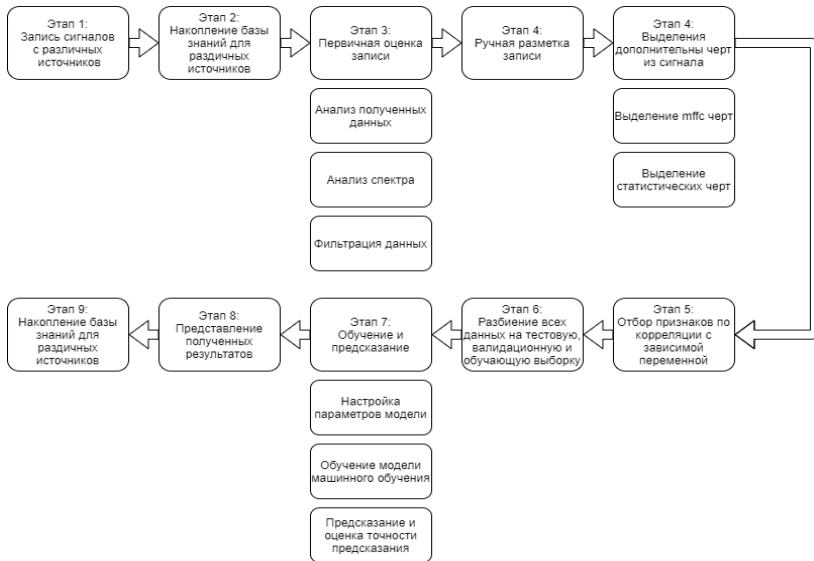


Рис. 11. Этапы алгоритма классификации типа сигнала, направления и расстояния до источника его возбуждения

На первом этапе производится запись эксперимента. Участок проведения тщательно размечается, производится записи о размерах, реперных точках и используемых датчиков в базу данных.

Далее данные загружаются в программу первичной обработки, визуализируются, и проводится первичная оценка их адекватности. В

соответствии с целями проводится фильтрация сигналов, данные о примененных фильтрах также хранятся в базе данных.

На третьем этапе проводится ручная разметка записи. В случае с классификацией сигнала размечается начало сигнала и его длительность, а в случае с расстоянием до источника возбуждения берутся данные о начале и длительности сигнала, и добавляется информация о расстоянии до записывающего сигналы прибора. В случае с определением угла к данным добавляются информация об угле отклонения источника сигнала от прибора.

На четвертом этапе производится извлечение различных характеристик сигнала. Так как общее количество параметров может превышать количество пар амплитуда-фаза для заданного отрезка, что неизбежно приводит к переобучению модели, проводится отбор параметров на основе таблицы корреляции. На вход моделям машинного обучения подаются параметры с силой корреляции не менее 0.2.

Далее данные перемешиваются в случайном порядке, разбиваются на три выборки в соотношении 0.7 : 0.15 : 0.15: тренировочная, валидационная и тестовая и подаются на вход модели машинного обучения. Обучающая выборка необходима непосредственно для обучения, на валидационной выборке модель улучшает свои параметры, в обеих упомянутых выборках модель имеет доступы к истинным ответам. Далее обученная модель получает тестовые данные. Здесь модель машинного обучения уже не имеет доступа к истинным ответам и производит расчёты на основе настроенных ранее параметрах. Полученный результат сравнивается с истинным с помощью различных метрик. На финальном этапе проводится анализ полученных результатов.

В качестве метода определения расстояния до источника сигнала был выбран метод машинного обучения на основе градиентного бустинга с применением ранее полученных статистических и MFCC параметров. Данные с экспериментов были размечены с учетом наличия классифицируемого сигнала, кроме того, были выставлены метки расстояний до этих источников. Метод градиентного бустинга был применен для обучения на тестовых данных на основе выделенных параметров. Обученная модель далее была проверена на новых экспериментальных данных. На рисунке 12 представлены результаты сравнения работы модели и истинных результатов для задачи определения расстояния до источников сигнала. Модель ошибается в определении расстояния в отдельных точках, но хорошо ложится на кривую истинного расстояния.




Рис. 12. Сравнение прогнозов моделей по определению расстояния до источника сигнала, обученных на разных наборах параметров. STAT - статистические параметры, MFCC – кепстральные коэффициенты, STAT+MFCC – их совместное применение. Оранжевым цветом обозначен ожидаемый результат, а синим – результат, выданный моделью. По оси x – номер сигнала, по оси y – дистанция в метрах

Модель была обучена с помощью статистических характеристик, с помощью MFCC параметров, а также с совместным их применением. Видно, что если оценивать эксперимент в целом, то в пределах 25 метров все модели показывают результат близкий к истинному. В то же время при оценке дистанции в каждый момент наличия источника сигнала, статистические характеристики дают наихудший результат. Совместное применение MFCC и статистических характеристик дает наилучшие результаты. В тоже время, стоит помнить, что на небольшом количестве экспериментов может появиться переобучение модели машинного обучения, и вследствие чего корректное предсказание новых данных будет затруднено.

Таким образом, наглядно продемонстрировано, что для улучшения качества определения расстояния до источника, необходимо проводить множество экспериментов, при этом чем больший объем новых данных будет получен, тем точнее будет модель. В то же время показано, что на удалении более чем на 25 метров от датчиков для регистрации угловых и линейных колебаний в сейсмическом волновом поле поверхностных источников, определение расстояния до источника, с использованием текущей элементной базы, становится затруднительным.

В таблице 3 показано применение обученной модели ко всем экспериментам, в качестве метрики – среднеквадратичная ошибка (Root Mean Square Error), рассчитанная по всем данным из тестовой выборки для заданного эксперимента. Чем меньше полученное

значение, тем выше качество модели. Лучшие показатели достигаются путем совместного применения статистических и MFCC параметров.

Таблица 3. Точность определения расстояния до источника сигнала, метрика Root Mean Square Error

	Эксперимент А (максимальное удаление от сенсоров 34 м)	Эксперимент В (максимальное удаление от сенсоров 34 м)	Эксперимент С (максимальное удаление от сенсоров 28 м)	Эксперимент D (максимальное удаление от сенсоров 28 м)
STAT	4.272	5.359	2.87	2.982
MFCC	4.372	5.630	3.62	3.526
STAT + MFCC	4.135	5.041	2.84	2.678

В работе определялось направление на источник сигнала, с помощью данных, полученных с линейного вертикального датчика и двух ортогональных датчиков вращательных движений. Для этого был использован алгоритм градиентного бустинга, обученный на тех же вариантах набора параметров: статистические, MFCC, и их комбинация (рисунок 13).




Рис. 13. Сравнение прогнозов моделей для определения направления на источник сигнала, обученных на разных наборах параметров. STAT – статистические параметры, MFCC – кепстральные коэффициенты, STAT+MFCC – их совместное применение. Оранжевым цветом обозначен ожидаемый результат, а синим – результат, выданный моделью. По оси x – номер сигнала, по оси y – угол в радианах

Кроме того, было выполнено сравнение результата обучения модели с направлением на источник сигнала, полученным исходя из особенностей распространения Рэлеевской волны в поверхностной плоскости (рисунок 14). Этот результат был получен исходя из предположения, что движение в вертикальной плоскости обусловлено Рэлеевской волной, таким образом, математически скалярное произведение сигнала с вертикальной компоненты с соответствующими сигналами с горизонтальных компонент вращательных датчиков, явно обуславливает направление распространения Рэлеевской волны, а направление на источник, соответственно, обратно направлению волны.




Рис. 14. Результат вычисления направления на источник. Оранжевым цветом обозначен ожидаемый результат, а синим – вычисленный. По оси x – номер сигнала, по оси y – угол в радианах

Заметно, что результаты вычисления угла, в целом, достаточно неплохо соответствуют моделям градиентного бустинга (выбросы вблизи 60-80 соответствуют разности фаз в 2π).

6. Заключение. Таким образом, в рамках работы разработан и протестирован в лабораторных и полевых условиях прототип шестикомпонентного измерительного комплекса для проведения экспериментальных исследований сейсмических событий на основе измерения характеристик граничных волн, создаваемых поверхностными источниками с использованием специальных датчиков. Каждый датчик в составе измерительного комплекса содержит чувствительные молекулярно-электронные элементы угловых и линейных колебаний и характеризуется селективной способностью регистрировать сдвиговую компоненту волнового поля

с высокой чувствительностью. На основе экспериментов впервые удалось получить комплексные и всесторонние исследовательские данные о характере распространения возмущений от поверхностных источников, а также об особенностях распространения волнового сигнала в ближней зоне.

Предложена и апробирована на экспериментальных данных модель волнового процесса распространения сейсмических возмущений от поверхностного источника. Новизна модели обусловлена применением 6-компонентной поляризационной модели для различных типов волн. На основе модели разработан алгоритм, который позволяет автоматически идентифицировать и, соответственно, отделять приходящие волны на основе их поляризационных характеристик.

Представлен алгоритм обработки данных, получаемых по методике сейсмических наблюдений с использованием датчиков для регистрации угловых и линейных колебаний в сейсмическом волновом поле поверхностных источников. Алгоритм обработки использует вейвлет анализ на основе вейвлета Морле. Было установлено, что наибольшая плотность сигнала находится в области от 10 до 35 Гц. Был использован цифровой фильтр Баттерворта 2го порядка с частотами среза 10 и 35 Гц.

Для разработки алгоритма анализа данных для определения расстояния и азимута до пункта возбуждения поверхностных волн, были рассмотрены несколько подходов: использование статистических характеристик и технологии с применением черт MFCC (Мел-частотные кепстральные коэффициенты), а также их совместное применение. Наилучший результат достигается путем совместного применения статистических и MFCC характеристик. При небольшом отдалении от сенсора, до 25 метров, оказалось достаточным использовать только статистические характеристики. Полученные результаты показывают возможность корректной идентификации источника на уровне около 80%.

Отметим, что представленные результаты уникальны тем, что предполагают использование единственного точечного приемника, то есть принципиально не использует данные по времени задержки сигнала. Указанное справедливо как при реализации алгоритмов идентификации источника, так и для определения координат источника в полярной системе координат.

Литература

1. Sun L., Wang Y., Yang J., Zhang Y., Wang S. Progress in Rotational Seismology. *Earth Science*. 2021. 46(4). pp. 1518-1536.
2. Kurrle D., Igel H., Ferreira A.M.G., Wassermann J., and Schreiber U. Can we estimate local Love wave dispersion properties from collocated amplitude measurements of translations and rotations? *Geophysical research letters*. 2010. vol. 37.
3. Schmelzbach C., Donner S., Igel H., Sollberger D., Taufiqurrahman T., Bernauer F., Hausler M., van Renterghem C., Wassermann J., Robertsson J. Advances in 6C seismology: Applications of combined translational and rotational motion measurements in global and exploration seismology. *Geophysics*. 2018. vol. 83. WC53-WC69.
4. Li Z., van der Baan M. Seismology Elastic passive source localization using rotational motion. *Geophys. J. Int.* 2017. vol. 211. pp. 1206-1222.
5. Van Renterghem C., Schmelzbach C., Sollberger D., Robertsson J.O.A. Spatial wavefield gradient-based seismic wavefield separation. *Geophys. J. Int.* 2018. vol. 212. p. 2017.
6. Sollberger D., Greenhalgh S.A., Schmelzbach C., Van Renterghem C., Robertsson J.O.A. 6-C polarization analysis using point measurements of translational and rotational ground-motion: theory and applications. *Geophysical Journal International*. 2018. vol. 213.
7. Schmidt R.O. Multiple Emitter Location and Signal Parameter Estimation. *IEEE Trans. Antennas Propagation*, 1986. vol. AP-34. pp. 276-280.
8. Trifunac M.D. Effects of torsional and rocking excitations on the response of structures. In *Earthquake Source Asymmetry. Structural Media and Rotation Effects*, Ed. Teisseyre R., Takeo M., Majewski E., Berlin: Springer, 2006. pp. 569-582.
9. Jalali R.S., Trifunac M.D. Response spectra for near-source, differential and rotational strong motion. *Bulletin of the Seismological Society of America*. 2009. vol. 99 (2B), pp. 1404-1415.
10. Zembaty Z. Rotational seismic load definition in Eurocode 8, Part 6 for slender, tower-shaped structures. *Bulletin of the Seismological Society of America*. 2009. vol. 99 (2B), pp. 1483-1485.
11. Gicev V., Trifunac M.D. Transient and permanent rotations in a shear layer excited by strong earthquake pulses. *Bulletin of the Seismological Society of America*. 2009. vol. 99 (2B), pp. 1391-1403.
12. Trifunac M.D. 75th anniversary of strong motion observation – a historical review. *Soil Dynamics and Earthquake Engineering*. 2009. vol. 29 (4), pp. 591-606.
13. Шевченко Д.В., Шевченко В.П. Выбор и оптимизация структуры построения автономных сейсмических средств обнаружения рубежного типа // *Материалы VIII всероссийской научно-технической конференции «Современные охранные технологии и средства обеспечения комплексной безопасности объектов»*. 2010. С. 128–133.
14. Вольсков А.А. Выбор частоты дискретизации сигнала для решения задачи пассивной сейсмической пеленгации // *Материалы VIII Всероссийской научно-технической конференции «Современные охранные технологии и средства обеспечения комплексной безопасности объектов»*. 2010. С. 128–133
15. Igel H., Bernauer M., Wassermann J., Schreiber K.U. *Seismology, rotational, complexity: Encyclopedia of complexity and systems science*: Springer Science and Business Media New York, 2015.
16. Lee W.H.K., Igel H., Trifunac M.D. Recent advances in rotational seismology. *Seismological Research Letter*. 2009. vol. 80. no. 3. pp. 479–490.

17. Van Driel M., Wassermann J., Nader M.F., Schubert H.B.S.A., Igel H. Strain rotation coupling and its implications on the measurement of rotational ground motions. *Journal of Seismology*. 2012. vol. 16. no. 4. pp. 657–668.
18. Muzyert E., Kashubin A., Kragh E., Edme P. Land seismic data acquisition using rotation sensors. 74th EAGE Conference & Exhibition incorporating SPE EUROPEC, 2012. pp. 1–5.
19. Агафонов В.М., Афанасьев К.А., Яшкин А.В. Определение направления на движущийся объект с использованием сейсмического модуля, содержащего молекулярно-электронные датчики движения. *Труды МФТИ*. 2013. Т. 5. № 2. С. 142–149.
20. Li Z., Van der Baan M. Enhanced microseismic event localization by reverse time extrapolation. *SEG Technical Program Expanded Abstracts*. 2015, pp. 4111–4115.
21. Li Z.H., Van der Baan M. Elastic passive source localization using rotational motion. *Geophysical Journal International*. 2017. vol. 211(2). pp. 1206–1222.
22. Barak O., Herkenhoff F., Dash R., Jaiswal P., Giles J., de Ridder S., Brune R., Ronen S. Six-component seismic land data acquired with geophones and rotation sensors: Wave-mode selectivity by application of multicomponent polarization filtering. *The Leading Edge*. 2014. vol. 11. pp. 1224–1232.
23. Edme P., Muzyert E. Rotational data measurement. 75th EAGE Conference and Exhibition incorporating SPE EUROPEC, 2013. pp. 1–4.
24. Edme P., Muzyert E. Efficient land seismic acquisition sampling using rotational data. 76th EAGE Conference and Exhibition. Extended abstract, 2014. pp. 1–4.
25. Патент США US9766355B2 Use of vector rotational measurements and vector pressure gradient measurements to enhance spatial sampling of dual-sensor water bottom seismic data. 19/09/2017.
26. Патент США US9664806B2 Method to improve spatial sampling of vertical motion of seismic wavefields on the water bottom by utilizing horizontal rotational motion and vertical motion sensors. 30/05/2017.
27. Патент Китай CN110612462A System and method for formation evaluation from a wellbore. 24/12/2019.
28. Egorov E., Agafonov V., Avdyukhina S., Borisov S. Angular Molecular–Electronic Sensor with Negative Magnetohydrodynamic Feedback Sensors. 2018. vol. 18, p. 245.
29. Anikin, E. Egorov E., Agafonov V. Mechanical sensors Dependence of Self-Noise of the Angular Motion Sensor Based on the Technology of Molecular–Electronic Transfer, on the Area of the Electrodes. *IEE Sensors Lett.*, 2018. vol. 2. no. 2. pp. 1–4.
30. Zaitsev D., Shabalina A. The features of low-temperature operation for electrochemical sensors of motion parameters for the economic development of the arctic region of the Russian Federation in the fields of geophysics, seismology and seismic exploration, 21st International Multidisciplinary Scientific GeoConference SGEM, 2021. vol. 21, no. 1.1. pp. 759–768.
31. Zaitsev D., Egorov I., Agafonov V. A Comparative Study of Aqueous and Non-Aqueous Solvents to Be Used in Low-Temperature Serial Molecular–Electronic Sensors. *Chemosensors*, 2022.
32. Egorov E., Shabalina A., Zaitsev D., Kurkov S., Gueorguiev N. Frequency Response Stabilization and Comparative Studies of MET Hydrophone at Marine Seismic Exploration Systems. *Sensors*, 2020.
33. Chikishev D.A., Zaitsev D.L., Belotelov K.S., Egorov I.V. The Temperature Dependence of Amplitude- Frequency Response of the MET Sensor of Linear Motion in a Broad Frequency Range, in *IEEE Sensors Journal*, 2019. vol. 19. no. 21. pp. 9653–9661.
34. Neeshpapa A., Antonov A., Zaitsev D., Egorov E., Agafonov V. Geophysical system of permanent installation for underwater monitoring of seismic events, 20th

- International Multidisciplinary Scientific GeoConference SGEM, 2020. vol. 20. no. 1.3. pp. 17-24.
35. Li M., Shen H., Guo Yu., Mengxiong X. Locating microseismic events using multiplicative time reversal imaging based on decoupled wavefields in 2D VTI media: Theoretical and synthetic cases studies, *Journal of Petroleum Science and Engineering*, 2021. vol. 202. p. 108547.
 36. Sollberger D., Igel H., Schmelzbach C., Edme P., van Manen D.-J., Bernauer F., Yuan S., Wassermann J., Schreiber U., Robertsson J.O.A. Seismological Processing of Six Degree-of-Freedom Ground-Motion Data. *Sensors*, 2020. vol. 20. p. 6904. doi: 10.3390/s20236904.
 37. Pytel W., Fuławka K., Mertuszka P., Pałac-Walko B. Validation of Rayleigh Wave Theoretical Formulation with Single-Station Rotational Records of Mine Tremors in Lower Silesian Copper Basin. *Sensors*, 2021. vol. 21. p. 3566. doi: 10.3390/s21103566.
 38. Available at: http://r-sensors.ru/ru/products/data_loggers/ndas-8226_rus/ (accessed 06/09/2022).
 39. Кулеш М.А., Диалло М.С., Хольнайдер М. Вейвлет-анализ эллиптических, дисперсионных и диссипативных свойств волн Рэлея // *Акустический журнал*. 2005. Т. 51. № 4. С. 500-510.
 40. Davis S., Mermelstein P. Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1980. vol. 28. no. 4. pp. 357–366.
 41. O'Shaughnessy D. *Speech Communication: Human and Machine*. Addison-Wesley Pub. Co., 1987. p. 150.
 42. Опленгейм А.В., Шафер Р.В. *Цифровая обработка сигналов. Digital Signal Processing (рус.) / Пер. с англ. / Под ред. С.Я. Шаца. М.: Связь, 1979.*
 43. Zheng F., Zhang G., Song Z. COMPARISON OF DIFFERENT IMPLEMENTATIONS OF MFCC J. *Computer Science & Technology*, 2001. vol. 16(6). pp. 582-589.
 44. Xie T., Zheng X., Zhang Y. Seismic facies analysis based on speech recognition feature parameters. *Geophysics*. 2017. vol. 82. no. 3. pp. 023–035.
 45. Friedman J.H. *Greedy Function Approximation: A Gradient Boosting Machine*, 1999.
 46. Zheng F., Zhang G., Song Z. Comparison of different implementations of MFCC J. *Computer Science & Technology*. 2001. vol. 16(6). pp. 582-589.
 47. Powers D.M.W. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*. 2011.

Зайцев Дмитрий Леонидович — канд. физ.-мат. наук, старший научный сотрудник, ООО «Р-сенсор». Область научных интересов: физическая электроника, приборостроение, информационные системы, сейсмика, геофизика, электрохимия. Число научных публикаций — 60. Zaitcev.dl@mipt.ru; Лихачевский проезд, 4/1, 141700, Долгопрудный, Россия; р.т.: +7(498)744-6995.

Брыксин Виталий Михайлович — канд. техн. наук, доцент, старший научный сотрудник, НИИ прикладной информатики и математической геофизики БФУ им. И. Канта. Область научных интересов: математическая моделирование, численные методы, дистанционное зондирование, геофизика. Число научных публикаций — 130. vbryksin@kantiana.ru; улица Александра Невского, 14, 236041, Калининград, Россия; р.т.: +7(4012)595-558.

Белотелов Константин Сергеевич — ведущий инженер, ООО «Р-сенсорс». Область научных интересов: математическая статистика, теория вероятности, машинное обучение, математическое моделирование, сейсмика, геофизика, электрохимия. Число научных публикаций — 12. costia.17@gmail.com; Лихачевский проезд, 4/1, 141700, Долгопрудный, Россия; р.т.: +7(498)744-6995.

Компаниец Юлия Игоревна — инженер, ООО «Р-сенсорс». Область научных интересов: математическая статистика, теория вероятности, машинное обучение, математическое моделирование. Число научных публикаций — 3. kompaniets.yu@ya.ru; Лихачевский проезд, 4/1, 141700, Долгопрудный, Россия; р.т.: +7(498)744-6995.

Яковлев Роман Никитич — младший научный сотрудник, лабораторий технологий больших данных социоконвергентных систем, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: модели, технологии и архитектуры конвергентных и социоконвергентных систем, модели машинного обучения в компьютерном зрении. Число научных публикаций — 30. iakovlev.r@mail.ru; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-3311.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда № 22-69-00231, <https://rscf.ru/project/22-69-00231/>.

D. ZAITSEV, V. BRYK SIN, K. BELOTELOV, Y. KOMPANIETS, R. IAKOVLEV
**ALGORITHMS AND MEASURING COMPLEX FOR
CLASSIFICATION OF SEISMIC SIGNAL SOURCES,
DETERMINATION OF DISTANCE AND AZIMUTH TO THE
POINT OF EXCITATION OF SURFACE WAVES**

Zaitsev D., Bryksin V., Belotelov K., Kompaniets Y., Iakovlev R. Algorithms and Measuring Complex for Classification of Seismic Signal Sources, Determination of Distance and Azimuth to the Point of Excitation of Surface Waves.

Abstract. Machine learning and digital signal processing methods are used in various industries, including in the analysis and classification of seismic signals from surface sources. The developed wave type analysis algorithm makes it possible to automatically identify and, accordingly, separate incoming seismic waves based on their characteristics. To distinguish the types of waves, a seismic measuring complex is used that determines the characteristics of the boundary waves of surface sources using special molecular electronic sensors of angular and linear oscillations. The results of the algorithm for processing data obtained by the method of seismic observations using spectral analysis based on the Morlet wavelet are presented. The paper also describes an algorithm for classifying signal sources, determining the distance and azimuth to the point of excitation of surface waves, considers the use of statistical characteristics and MFCC (Mel-frequency cepstral coefficients) parameters, as well as their joint application. At the same time, the following were used as statistical characteristics of the signal: variance, kurtosis coefficient, entropy and average value, and gradient boosting was chosen as a machine learning method; a machine learning method based on gradient boosting using statistical and MFCC parameters was used as a method for determining the distance to the signal source. The training was conducted on test data based on the selected special parameters of signals from sources of seismic excitation of surface waves. From a practical point of view, new methods of seismic observations and analysis of boundary waves make it possible to solve the problem of ensuring a dense arrangement of sensors in hard-to-reach places, eliminate the lack of knowledge in algorithms for processing data from seismic sensors of angular movements, classify and systematize sources, improve prediction accuracy, implement algorithms for locating and tracking sources. The aim of the work was to create algorithms for processing seismic data for classifying signal sources, determining the distance and azimuth to the point of excitation of surface waves.

Keywords: boundary waves, molecular electronics, wavelet analysis, machine learning, azimuth determination, distance determination, data processing algorithm.

References

1. Sun L., Wang Y., Yang J., Zhang Y., Wang S. Progress in Rotational Seismology. Earth Science. 2021. 46(4). pp. 1518-1536.
2. Kurrle D., Igel H., Ferreira A.M.G., Wassermann J., Schreiber U. Can we estimate local Love wave dispersion properties from collocated amplitude measurements of translations and rotations? Geophysical research letters. 2010. vol. 37.
3. Schmelzbach C., Donner S., Igel H., Sollberger D., Taufiqurrahman T., Bernauer F., Häusler M., Van Renterghem C., Wassermann J., Robertsson J. Advances in 6C seismology: Applications of combined translational and rotational motion measurements in global and exploration seismology. Geophysics. 2018. vol. 83. pp. WC53-WC69.

4. Li Z., Van der Baan M. Seismology Elastic passive source localization using rotational motion Geophys. J. Int. 2017. vol. 211. pp. 1206–1222.
5. Van Renterghem C., Schmelzbach C., Sollberger D., Robertsson J.O.A. Spatial wavefield gradient-based seismic wavefield separation Geophys. J. Int. 2018. vol. 212. p. 2017.
6. Sollberger D., Greenhalgh S.A., Schmelzbach C., Van Renterghem C., Robertsson J.O.A. 6-C polarization analysis using point measurements of translational and rotational ground-motion: theory and applications. Geophysical Journal International. 2018. vol. 213.
7. Schmidt, R.O. "Multiple Emitter Location and Signal Parameter Estimation," IEEE Trans. Antennas Propagation, 1986. vol. AP-34. pp. 276–280.
8. Trifunac M.D. Effects of torsional and rocking excitations on the response of structures. In Earthquake Source Asymmetry. Structural Media and Rotation Effects, Ed. Teisseyre R., Takeo M., Majewski E., Berlin: Springer, 2006. pp. 569–582.
9. Jalali R.S., Trifunac M.D. Response spectra for near-source, differential and rotational strong motion. Bulletin of the Seismological Society of America. 2009. vol. 99 (2B), pp. 1404–1415.
10. Zembaty Z. Rotational seismic load definition in Eurocode 8, Part 6 for slender, tower-shaped structures. Bulletin of the Seismological Society of America. 2009. vol. 99 (2B), pp. 1483–1485.
11. Gicev V., Trifunac M.D. Transient and permanent rotations in a shear layer excited by strong earthquake pulses. Bulletin of the Seismological Society of America. 2009. vol. 99 (2B), pp. 1391–1403.
12. Trifunac M.D. 75th anniversary of strong motion observation – a historical review. Soil Dynamics and Earthquake Engineering. 2009. vol. 29 (4), pp. 591–606.
13. Shevchenko D.V., Shevchenko V.P. [The choice and optimization of the structure of the construction of autonomous seismic detection devices of the boundary type]. Materialy VIII vserossijskoj nauchno-tehnicheskoy konferencii «Sovremennyye ohrannyye tehnologii i sredstva obespecheniya kompleksnoy bezopasnosti obektov» [Modern security technologies and means of ensuring complex safety of objects: Materials of Conference], 2010. pp. 128–133. (In Russian).
14. Volskov A.A. [The choice of the sampling frequency of the signal for solving the problem of passive seismic direction finding]. Materialy VIII Vserossijskoj nauchno-tehnicheskoy konferencii «Sovremennyye ohrannyye tehnologii i sredstva obespecheniya kompleksnoy bezopasnosti obektov» [Materials of the Conferenc], 2010. pp. 128–133. (In Russ.).
15. Igel H., Bernauer M., Wassermann J., Schreiber K.U. Seismology, rotational, complexity: Encyclopedia of complexity and systems science: Springer Science and Business Media New York, 2015.
16. Lee W.H.K., Igel H., Trifunac M.D. Recent advances in rotational seismology. Seismological Research Letter. 2009. vol. 80. no. 3. pp. 479–490.
17. Van Driel M., Wassermann J., Nader M.F., Schubert B.S.A., Igel H. Strain rotation coupling and its implications on the measurement of rotational ground motions. Journal of Seismology. 2012. vol. 16. no. 4. pp. 657–668.
18. Muzert E., Kashubin A., Kragh E., Edme P. Land seismic data acquisition using rotation sensors. 74th EAGE Conference & Exhibition incorporating SPE EUROPEC, 2012. pp. 1–5.
19. Agafonov V.M., Afanasyev K.A., Yashkin A.V. [Determination of the direction to a moving object using a seismic module containing molecular electronic motion sensors]. Trudy MFTI – Proceedings of MIPT. 2013. vol. 5. no. 2. pp. 142–149. (In Russ.).
20. Li Z., Van der Baan M. Enhanced microseismic event localization by reverse time extrapolation. SEG Technical Program Expanded Abstracts. 2015, pp. 4111–4115.
21. Li Z.H., Van der Baan M. Elastic passive source localization using rotational motion. Geophysical Journal International. 2017. vol. 211(2). pp. 1206–1222.

22. Barak O., Herkenhoff F., Dash R., Jaiswal P., Giles J., de Ridder S., Brune R., Ronen S. Six-component seismic land data acquired with geophones and rotation sensors: Wave-mode selectivity by application of multicomponent polarization filtering. *The Leading Edge*. 2014. vol. 11. pp. 1224–1232.
23. Edme P., Muyzert E. Rotational data measurement. 75th EAGE Conference and Exhibition incorporating SPE EUROPEC, 2013. pp. 1–4.
24. Edme P., Muyzert E. Efficient land seismic acquisition sampling using rotational data. 76th EAGE Conference and Exhibition. Extended abstract, 2014. pp. 1–4.
25. US9766355B2 [Use of vector rotational measurements and vector pressure gradient measurements to enhance spatial sampling of dual-sensor water bottom seismic data]. 19/09/2017. (In Russ.).
26. US9664806B2 [Method to improve spatial sampling of vertical motion of seismic wavefields on the water bottom by utilizing horizontal rotational motion and vertical motion sensors]. 30/05/2017. (In Russ.).
27. CN110612462A [System and method for formation evaluation from a wellbore]. 24/12/2019. (In Russ.).
28. Egorov E., Agafonov V., Avdyukhina S., Borisov S. Angular Molecular–Electronic Sensor with Negative Magnetohydrodynamic Feedback Sensors. 2018. vol. 18, p. 245.
29. Anikin, E. Egorov E., Agafonov V. Mechanical sensors Dependence of Self-Noise of the Angular Motion Sensor Based on the Technology of Molecular-Electronic Transfer, on the Area of the Electrodes. *IEE Sensors Lett.*, 2018. vol. 2. no. 2. pp. 1–4.
30. Zaitsev D., Shabalina A. The features of low-temperature operation for electrochemical sensors of motion parameters for the economic development of the arctic region of the Russian Federation in the fields of geophysics, seismology and seismic exploration, 21st International Multidisciplinary Scientific GeoConference SGEM, 2021. vol. 21, no. 1.1. pp. 759-768.
31. Zaitsev D., Egorov I., Agafonov V. A Comparative Study of Aqueous and Non-Aqueous Solvents to Be Used in Low-Temperature Serial Molecular–Electronic Sensors. *Chemosensors*, 2022.
32. Egorov E., Shabalina A., Zaitsev D., Kurkov S., Gueorguiev N. Frequency Response Stabilization and Comparative Studies of MET Hydrophone at Marine Seismic Exploration Systems. *Sensors*, 2020.
33. Chikishev D.A., Zaitsev D.L., Belotelov K.S., Egorov I.V. The Temperature Dependence of Amplitude- Frequency Response of the MET Sensor of Linear Motion in a Broad Frequency Range, in *IEEE Sensors Journal*, 2019. vol. 19. no. 21. pp. 9653-9661.
34. Neeshpapa A., Antonov A., Zaitsev D., Egorov E., Agafonov V. Geophysical system of permanent installation for underwater monitoring of seismic events, 20th International Multidisciplinary Scientific GeoConference SGEM, 2020. vol. 20. no. 1.3. pp. 17-24.
35. Li M., Shen H., Guo Yu., Mengxiong X. Locating microseismic events using multiplicative time reversal imaging based on decoupled wavefields in 2D VTI media: Theoretical and synthetic cases studies, *Journal of Petroleum Science and Engineering*. 2021. vol. 202. p. 108547.
36. Sollberger D., Igel H., Schmelzbach C., Edme P., van Manen D.-J., Bernauer F., Yuan S., Wassermann J., Schreiber U., Robertsson J.O.A. Seismological Processing of Six Degree-of-Freedom Ground-Motion Data. *Sensors*, 2020. vol. 20. p. 6904. doi: 10.3390/s20236904.
37. Pytel W., Fuławka K., Mertuszka P., Pałac-Walko B. Validation of Rayleigh Wave Theoretical Formulation with Single-Station Rotational Records of Mine Tremors in Lower Silesian Copper Basin. *Sensors*, 2021. vol. 21. p. 3566. doi: 10.3390/s21103566.
38. Available at: http://r-sensors.ru/ru/products/data_loggers/ndas-8226_rus/ (accessed 06/09/2022).

39. Kulesh M.A., Diallo M.S., Holschneider M. [Wavelet analysis of elliptical, dispersive and dissipative properties of Rayleigh waves]. *Akusticheskij zhurnal – Acoustic Journal*. 2005. vol. 51. no. 4. pp. 500-510. (In Russ.).
40. Davis S., Mermelstein P. Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1980. vol. 28. no. 4. pp. 357–366.
41. O'Shaughnessy D. *Speech Communication: Human and Machine*. Addison-Wesley Pub. Co., 1987. p. 150.
42. Oppenheim A.V., Schaffer R.V. [Digital Signal Processing] (Russ. ed.: Shac S.Ja.). M.: Svyaz', 1979. (In Russ.).
43. Zheng F., Zhang G., Song Z. COMPARISON OF DIFFERENT IMPLEMENTATIONS OF MFCC *J. Computer Science & Technology*, 2001. vol. 16(6). pp. 582-589.
44. Xie T., Zheng X., Zhang Y. Seismic facies analysis based on speech recognition feature parameters. *Geophysics*. 2017. vol. 82. no. 3. pp. 023–035.
45. Friedman J.H. *Greedy Function Approximation: A Gradient Boosting Machine*, 1999.
46. Zheng F., Zhang G., Song Z. Comparison of different implementations of MFCC *J. Computer Science & Technology*. 2001. vol. 16(6). pp. 582-589.
47. Powers D.M.W. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*. 2011.

Zaitsev Dmitry — Ph.D., Senior researcher, R-sensors LLC. Research interests: physical electronics, instrumentation, information systems, seismics, geophysics, electrochemistry. The number of publications — 60. Zaitcev.dl@mipt.ru; 4/1, Likhachevsky proezd, 141700, Dolgoprudny, Russia; office phone: +7(498)744-6995.

Bryksin Vitaliy — Ph.D., Associate Professor, Senior researcher, Research Institute of Applied Informatics and Mathematical Geophysics of Immanuel Kant Baltic Federal University. Research interests: mathematical modeling, numerical methods, remote sensing, geophysics. The number of publications — 130. vbryksin@kantiana.ru; 14, Alexander Nevsky St., 236041, Kaliningrad, Russia; office phone: +7(4012)595-558.

Belotelov Konstantin — Leading engineer, R-sensors LLC. Research interests: mathematic statistics, machine learning, probability theory, mathematical modeling, seismics, geophysics, electrochemistry. The number of publications — 12. costia.17@gmail.com; 4/1, Likhachevsky proezd, 141700, Dolgoprudny, Russia; office phone: +7(498)744-6995.

Kompaniets Yulia — Engineer, R-sensors LLC. Research interests: mathematic statistics, machine learning, probability theory, mathematical modeling. The number of publications — 3. kompaniets.yu@ya.ru; 4/1, Likhachevsky proezd, 141700, Dolgoprudny, Russia; office phone: +7(498)744-6995.

Iakovlev Roman — Junior researcher, Laboratory of big data technologies in socio-cyberphysical systems, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: models, technologies and architectures of cyberphysical and socio-cyberphysical systems, machine learning models in computer vision. The number of publications — 30. iakovlev.r@mail.ru; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-3311.

Acknowledgements. The study was supported by the Russian Science Foundation grant No.22-69-00231, <https://rscf.ru/en/project/22-69-00231/>.

G. TSOICHEV, K. POPOVA, I. STANKOV
**A COMPARATIVE STUDY BY SIMULATION OF OSPF AND
EIGRP ROUTING PROTOCOLS**

Tsoichev G., Popova K., Stankov I. A Comparative Study by Simulation of OSPF and EIGRP Routing Protocols.

Abstract. Computer networks are based on technology that provides the technical infrastructure where routing protocols are used to transmit packets over the Internet. Routing protocols define how routers communicate with each other by distributing information. They are used to describe how routers communicate with each other, learn available routes, build routing tables, make routing decisions, and share information between neighbors. The main purpose of routing protocols is to determine the best route from source to destination. A particular case of a routing protocol operating within an autonomous system is called an internal routing protocol (IGP – Interior Gateway Protocol). The article analyzes the problem of correctly choosing a routing protocol. Open Shortest Path First (OSPF) and Enhanced Interior Gateway Routing Protocol (EIGRP) are considered leading routing protocols for real-time applications. For this they are chosen to be studied. The main objective of the study is to compare the proposed routing protocols and to evaluate them based on different performance indicators. This assessment is carried out theoretically – by analyzing their characteristics and action, and practically – through simulation experiments. After the study of the literature, the simulation scenarios and quantitative indicators by which the performance of the protocols is compared are defined. First, a network model with OSPF is designed and simulated using the OPNET Modeler simulator. Second, EIGRP is implemented in the same network scenario and a new simulation is done. The implementation of the scenarios shall collect the necessary results and analyze the operation of the two protocols. The data shall be derived and an assessment and conclusion shall be made against the defined quantitative indicators.

Keywords: routing protocols, convergence, bandwidth, computer networks, throughput, network topology, OSPF, EIGRP.

1. Introduction. In the modern age, computer communication networks develop and grow by the day. Computer networks are based on technology that provides the technical infrastructure, where routing protocols are used to transmit packages over the Internet. Routing protocols determine how routers communicate with each other by disseminating information. These protocols help routers find neighbors, monitor connections between them, study new routers, and recover quickly from sudden damage to connected or remote connections.

Among the various routing protocols, Open Shortest Path First (OSPF) and Enhanced Interior Gateway Routing Protocol (EIGRP) are considered the leading routing protocols for real-time applications. OSPF is a "link-state interior gateway" protocol based on a Dijkstra's algorithm – the shortest path algorithm (Dijkstra's Shortest Path First Algorithm – SPF). On the other hand, EIGRP is a 'distance-vector' Cisco protocol based on a Diffusing Update Algorithm (DUAL).

When selecting a routing protocol, factors such as network size, hierarchical structure, multiple equal or uneven paths to networks and bandwidth of connections must be taken into account. This makes it obvious that poor choice of a routing protocol can lead to reduced performance, route cycles, and low quality of service.

The main objective of the study is to compare the proposed routing protocols and to evaluate them based on different performance indicators. This assessment is carried out theoretically – by analyzing their characteristics and action, and practically – through simulation experiments.

In the first part, the OSPF and EIGRP protocols are presented, analyzed and explained on the basis of their operational and convergent behavior. Because they implement unique algorithms, namely SPF and DUAL, and use different metrics based on "value" (OSPF) and bandwidth, load and reliability (EIGRP), they work differently on topologies that, when scaled, present non-hierarchical forms or inefficient route summarization structures. [3] The impact of the inherent behavior of each protocol directly affects productivity in such cases, which has been demonstrated by simulation experiments.

To evaluate the performance of routing protocols, OSPF and EIGRP, the following tasks are assigned:

- Presentation of the different characteristics of the routing protocols;
- Implementation of the proposed routing protocols in IP networks;
- Selection of quantitative indicators – convergence activity, end-to-end delay, variation of package delay, flickering, loss of traffic and bandwidth;
- Analysis of the work of each protocol – theoretically and by simulation;
- Create a simulation environment that can be used for further research.

2. Methodology. The available scientific and technical literature has been used for the performance of the research. By reviewing and analyzing scientific papers and publications, an expanded study of the characteristics of the OSPF and EIGRP routing protocols has been done.

After the study of the literature, the simulation scenarios and quantitative indicators by which the performance of the protocols is compared are defined. First, a network model with OSPF is designed and simulated using the OPNET Modeler simulator. Second, EIGRP is implemented in the same network scenario and a new simulation is done. The implementation of the scenarios shall collect the necessary results and

analyze the operation of the two protocols. The data shall be derived and an assessment and conclusion shall be made against the defined quantitative indicators.

3. Overview of OSPF and EIGRP

3.1. Definition and types. The network layer in the OSI reference model (Open Systems Interconnection Basic Reference Model) ensures that packages are transferred to the network. Routing protocols determine the path of each source package to the destination. To complete this task, routers use routing tables that contain information about possible destinations on the network and metrics (distance, "value", bandwidth, etc.) to these destinations [1].

Routing protocols are used to describe how routers communicate with each other, learn available routes, build routing tables, make routing decisions, and share information between neighbors. The main purpose of routing protocols is to determine the best route from source to destination. The routing algorithm uses different metrics based on one or more path properties to determine the best way to reach a network [2].

Routers are connected to multiple networks. When they receive a package on one of their interfaces, they check that the package is intended for the same network, to which that interface belongs. If so, they ignore the package. But if the package is intended for another network, then perform a search operation by searching their routing table, a local database, to find an output interface for forwarding the package. Therefore, the router performs two operations – a search process to find a route in their routing table, and a switching process to take a package from one interface and encapsulate it again to be sent to another interface [4].

To create a routing table, the router initially inserts into the table all the different networks that are directly connected to it and work. Then, it inserts all networks that are configured by the administrator by using static route commands. Finally, if a dynamic protocol is configured and running, the router inserts all routes learned through this protocol. If the steps described are completed, then the routing table is dynamic and changes every time there is an update in network topology [5].

Dynamic protocols are divided into different categories depending on whether they operate inside or outside an autonomous system (internal or external gateway protocols) or whether they implement a distance-vector protocol or a link-state protocol. Routing. Examples of internal gateway protocols are: RIPv1 and RIPv2, IGRP, EIGRP, OSPF and IS-IS, while the industry standard in the external gateway protocols is BGP [4] [5].

3.2. Distance vector routing. The term 'distance-vector routing' means that routing decisions are taken on the basis of route vectors

(together with relevant distances) learned from directly connected adjacent routing devices. Routers that route with a vector at a distance do not know the entire topology of the network, but only have knowledge of the distance from the destination network and the direction in which traffic should be forwarded. The routing protocols that belong to this category are: RIPv1m RIPv2, IGRP and EIGRP.

One of the main features of distance vector routing is that updates are sent periodically to all interfaces. These updates may contain the entire routing table or part of it (partial updates). When a participating router receives such an update, it compares with what it already knows from its table, covers all new information, updates existing information and shares what it knows with its neighbors [6].

This type of routing has some inherent problems with creating route cycles in case there are multiple routes to the destination. This happens because routers do not have a clear idea of the entire topology of the network, but believe what their neighbors "tell" them. Different ways of dealing with this problem have been developed [7].

3.3. Connection status routing. The term "link-state routing" means that routing decisions are taken individually for each router based on a network graph that exists in its memory. This graph contains the connections of all nodes in the autonomous system. The topology information allows each router to calculate the best path or paths to all different networks in the system. Which are then placed in the marching table. The main feature of this process is that the router should not periodically update its neighbors, but only when an event occurs. The routing protocols that belong to this category are: OSPF and IS-IS [8].

Connection status routing starts with the neighbor discovery phase, in which each router exchanges "hello" packages to find neighbors on all operational connections. Then the router "fills" its connected connections, so that all routers in the autonomous system learn the connections and those that produce them. This ends in a topology table of the connection supported by each router. This table, along with the adjacent table, allows each router to form a full topological view of the network [9].

The final stage is the implementation of an algorithm that produces the shortest path to each connection on the network, based on the parameter – "value" (cost) of the connection. A network column is created and the router starts running an algorithm for the shortest path, placing itself as the root of the source tree. The end result of the algorithm, which works independently on each router, fills in the routing tables in the autonomous system. A characteristic feature is that changes in topology lead to a recalculation of the algorithm for the shortest path and, as a result, to CPU

and memory usage. This type of routing takes precedence over vector distance routing, since all routers have knowledge of the entire topology [10].

3.4. OSPF. Open Shortest Path First is an internal protocol for routing the Internet Protocol (IP) network gateway. OSPF belongs to the family of connection status routing protocols and is used to distribute routing information within an autonomous system.

The name of the protocol depicts its two main characteristics. The first word "Open" refers to the fact that the protocol was developed using the open public RFC process (Request for Comments), and "Shortest Path First" refers to the Deakstra algorithm, in 1989, the first version of OSPF (OSPFv1) was created, drawn up in RFC 1131. In 1991, the second version (OSPFv2) was drafted and revised into RFC 1583, 2178 and 2328. In 1997, OSPFv3 was released in IPv6 RFC 2740 [11].

OSPF uses the Shortest Path Algorithm (SPF) to build and calculate the shortest path to all known destinations. Calculates using the Deakstra algorithm, which provides an optimal solution.

In a simplified way, the algorithm can be viewed in several steps:

- Each connection has a connected value and the goal is for each router to have a complete database of all connections that exist on the network;
- Link State Advertisements (LSA) ads are generated by the router when a change occurs on a connected network or during initialization;
- LSAs are exchanged through the procedure of "fill" between routers. Each router stores the resulting identical connection status update in its database and then distributes the update to other routers;
- When databases are created about the connection status in each router, the router running The Dijkstra algorithm creates a tree with the shortest paths to all destinations;
- If something changes on the network, the connection status protocol distributes it throughout the network, allowing all routers to keep up-to-date information [12].

The algorithm puts each router at the root of a tree and calculates the shortest path to each destination based on the cumulative costs required to reach that destination. Each router will have its own topology view, although all routers will build a tree with the shortest paths using the same connection status database [18].

The following lines summarize the main advantages and disadvantages of the OSPF protocol.

Advantages:

- The OSPF routing protocol is open unlike EIGRP, which is owned by Cisco;
- Cycle-free routes are always defined by OSPF;
- When changes occur, they spread quickly throughout the network.
- Use multicasting 224.0.0.5 to periodically send small hello packages checking connection performance without transferring the entire routing table, thus preserving the network bandwidth [13];
- Supports variable length subnet masks (VLSM) and CIDR by manual aggregation;
- Hierarchical protocol using Area 0 (Autonomous System) as the top of the hierarchy;
- "value" is used as an indicator;
- Suitable for large-scale networks;
- Uses low bandwidth;
- Supports multiple routes;
- Route exchanges are kept to a minimum and the size of the routing table is shortened by the architecture of the area;
- There are no limits on the number of jumps (hop);
- The OSPF package is indicated by IP header 89;
- Packages are routed based on their type of service.
- Disadvantages:
- OSPF configuration is complex to implement, as well as the removal of non-washes;
- Connection status scaling issues due mainly to LSA flooding;
- The SFP algorithm requires high CPU usage;
- More memory is needed to maintain neighborhood tables, routing and topology;
- Cannot maintain an uneven load balance.

3.5. EIGRP. Enhanced Interior Gateway Routing Protocol is a dynamic Cisco protocol for IP, IPX and AppleTalk networks, designed by Cisco Systems at the University of California in 1992.

EIGRP belongs to the family of distance vector routing protocols characterized as more advanced of its kind due to the fact that it is more scalable in medium and large networks. Although it belongs to the family of distance vectors, it carries characteristics of the connection state protocol and is publicly characterized as a hybrid remote vector protocol. It is used to distribute routing information within the same autonomous system, sending

gradual updates, and minimizing the amount of operation of the router, as well as the data required for transmission.

EIGRP uses both equal-cost load balancing (ECLB) and unequal-cost load balancing. EIGRP is the only protocol that essentially makes it an equal and unequal balancing of value load. This occurs by using the parameter "variance" [19].

The EIGRP links six different vector indicators to each route and takes into account only four of them to calculate the composite indicator. They are described in Table 1.

Table 1. EIGRP Indicators

Bandwidth	Minimum bandwidth on the way from the router to the destination
Load	Number ranging from 1 to 255
Total Delay	Delay on the way from router to destination.
Reliability	Number ranging from 1 to 255
Man	Maximum transmission unit. Not used in metric calculation.
Hop Count	Number of routers through which the package passes through the network. Not used in metric calculation.

EIGRP calculates routing metrics using the minimum bandwidth on the network path as well as the overall delay. Four vector metrics – bandwidth, reliability, delay and load – are connected to calculate the composite indicator for determining the preferred route (successor) [19].

The following lines summarize the main advantages and disadvantages of the EIGRP protocol.

Advantages:

- Use multicast 224.0.0.10 to send "Hello" packets checking connection performance without transferring the entire routing table, thereby storing the network bandwidth [15];
- Routes without cycles, thanks to Haze Condition (FC);
- Supports variable length subnet masks (VLSM) and CIDR, allowing automatic aggregation of routes on the network;
- Easy to configure;
- Fast convergence thanks to the dual algorithm. The EIGRP router stores all adjacent tables to adapt very quickly to alternative routes;
- EIGRP depends on the Reliable Transport Protocol (RTP) for the correct delivery of packages to all neighbors;
- The EIGRP package is indicated by IP header 88;

- Replacement routes through feasible successors;
- Activation updates shall notify when network changes occur;
- Supports aggregation in each interface, which reduces the routing table;
- Supports multiple network layer protocols, such as IP, IPX and Apple-Talk;
- Zoom for large dynamic multipoint deployments (DM).
- Disadvantages:
 - EIGRP summarizes routes in class borders automatically, by default. This function can be undone with the command "no auto-summary";
 - Owned by Cisco (only one part has been open source since 2013);
 - Difficulties in managing large hierarchical networks;
 - Routers from other providers cannot use EIGRP and therefore the redistribution of the protocol must be configured inside the autonomous system;
 - In any design, when the network increases significantly in size, cases of Stuck-In-Active can lead to slow convergence;
 - Triggers must be included in summarization.

3.6. Differences between OSPF and EIGRP based on literature.

Open Shortest Path First (OSPF) is a protocol for routing connection status. It collects connection status data from routers on the network and determines the information from the package forwarding route table. OSPF exchanges routing information only when there is a change in network topology. The protocol is best suited for complex networks that consist of multiple subnets working to facilitate administration and optimize traffic. OSPF effectively calculates the shortest path with minimal network traffic when the change occurs [14, 16].

Enhanced Interior Gateway Routing Protocol (EIGRP) is an advanced Cisco-based vector routing protocol. EIGRP is considered hybrid because it combines the characteristics of the remote routing protocol with a vector and the connection status routing protocol. It can determine the shortest vector of the distance on the road and uses indicators such as bandwidth, load and delays to calculate the shortest optimal route. EIGRP is a complex protocol, but can be configured and operates easily in small and large networks [14, 16].

The main differences between the two dynamic protocols are shown in Table 2.

Table 2. Comparison of the main characteristics of OSPF and EIGRP [17]

Characteristics	OSPF	EIGRP
Type of routing protocol	Connection Status <i>/Link state/</i>	Hybrid <i>/Hybrid/</i>
Standard	IETF Open Standard	Cisco Proprietary
Routing metrics	Interface bandwidth	Combination of bandwidth, reliability, load and delay
Administrative distance/distance	110	90 (Internal) 170 (External)
CPU requirements	High cpu and memory requirements	Lower cpu and memory requirements
Algorithm	Dijkstra link state	DUAL distance vector
Hierarchical design	Yes I do	Not
Complexity of implementation	Difficult	Easy, but without providing an automatic summary
Prevention of cycles	Full knowledge of topology	Split Horizon and DUAL
Filter & Summarize	ASBR or ABR only	Possible anywhere on the web

4. Simulation scenarios. Network simulation is the most useful and common methodology used to evaluate different network topologies – providing a real system through virtual reality. Network simulation is used in various fields and academic research, for industrial development, for analyzing, designing, simulating and checking the work of various network theories and hypotheses [20].

Modeling using a simulation tool – a simulator is the best way to conduct experiments in virtual environments that would otherwise be impractical due to the necessary equipment, the high cost to be spent, or even the fact that the system may not support extensive testing. A simulator is a computer-based mathematical software that performs multiple algorithms and equations to output results based on input data. This allows you to quickly and easily explore complex systems as well as scenarios under a wide range of conditions [22].

For the study in this research, the output results were obtained using a computer-based software simulation with OPNET Modeler – Edition 14.5. OPNET has a convenient graphical user interface that can be used to build different network configurations and test their performance [23]. Also, it contains a huge library of models that simulate most of the existing hardware devices and communication protocols. This makes it possible to easily simulate the most complex computer networks and configure

protocols that implement state-of-the-art communication technologies [21, 26]. Appropriate equipment is attached, as well as the necessary procedures for measuring the effectiveness of OSPF and EIGRP routing protocols on the basis of the desired quantitative indicators.

To achieve a simulation-based comparison between OSPF and EIGRP routing protocols, specific steps must be followed to design the simulator. Figure 1 shows a block-chart of steps.




Fig. 1. OPNET design and analysis

Two scenarios have been created that consist of three interconnected subnets, with routers in each subnet configured using OSPF and EIGRP routing protocols.

Network topology is composed of the following network drives and configuration utilities:

- CS_7000 Cisco Routers;
- CS_2948G Cisco Switches;
- Ethernet Workstations;
- Ethernet 1000BaseX Links;
- Application Configuration;
- Profile Configuration;
- Failure Recovery Configuration.

The design of the network topology is based on the geographical layout of Bulgaria, shown in Figures 2 and 3. Three subnets are considered – each of which is located in a different Bulgarian city – Sofia, Plovdiv, and Pleven. Subnets contain workstations, switches, routers, and connections. The internal infrastructure of network topology in individual cities is similar, that is why only one is shown in Figure 3.

The topology of Plovdiv and Pleven are similar.

The Application Definition Object and Profile Definition Object and saved as Application Config and Profile Config, have been added from the workspace object palette.

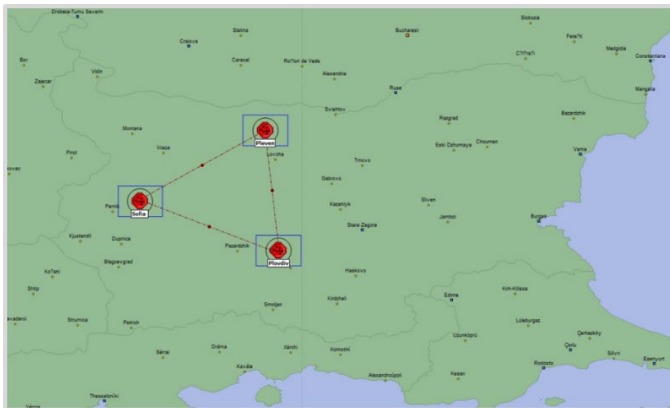


Fig. 2. Network Topology

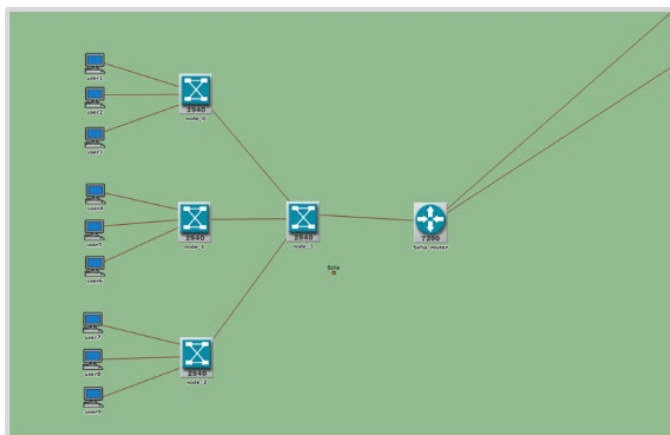


Fig. 3. Subnet – Sofia

Application Config enables the generation of different types of application traffic. In this research, the application definition object is set to support:

- Video Conferencing – High-Resolution Video;
- Voice – IP Telephony and Silence Suppressed;
- HTTP – Heavy Browsing.

Profile Config defines profiles within the defined traffic from the Application Definition Object. Three accounts have been created – to support Video Conferencing, Voice, and HTTP.

Failure Recovery is configured in the scenarios. Fault events cause interference in the routing topology, resulting in additional convergence activity intervals. Ten failed connections with different time intervals between the Sofia subnet and the Pleven subnet shown in Table 3 have been used.

Table 3. Failure recovery

Time (seconds)	Status
240	<i>Fail</i>
420	<i>Recover</i>
520	<i>Fail</i>
580	<i>Recover</i>
610	<i>Fail</i>
620	<i>Recover</i>
625	<i>Fail</i>
626	<i>Recover</i>
726	<i>Fail</i>
826	<i>Recover</i>

To evaluate the performance of OSPF and EIGRP dynamic routing protocols, two scenarios with the same network topologies were created. In the first scenario, the OSPF routing protocol is enabled for all routers on the network. After configuring it, individual DES statistics are set to select performance indicators and evaluate the behavior of the protocol. In the second scenario, the same steps are performed, but the configured protocol is EIGRP. The EIGRP network model is shown in Figure 4.

The performance of the two simulations is shown in Figure 5 and Figure 6. The graph depicts the differences between the current simulation speed and the average simulation speed measured in events/sec. The reporting time was 15 minutes, with the OSPF simulation at 848,011 events/sec and the EIGRP simulation at 920,337 events/sec. This indicates that more simulation events were performed in the second scenario per unit of time.

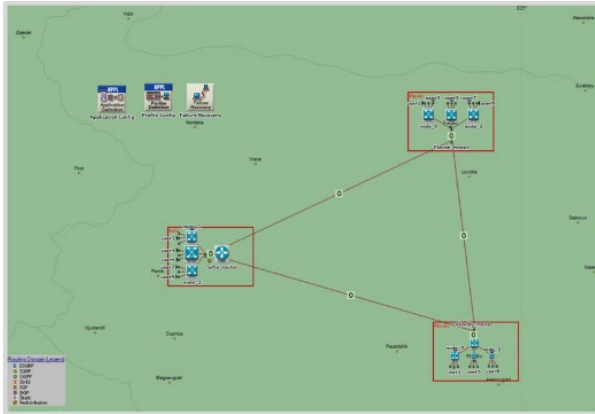


Fig. 4. EIGRP Scenario




Fig. 5. OSPF Simulation




Fig. 6. EIGRP Simulation

5. Results. Specific quantitative indicators were selected for the study to measure performance, as well as to assess the behavior of the OSPF and EIGRP protocols in each scenario. The quantitative indicators are presented graphically in OPNET.

The following quantitative indicators are measured:

- Network Convergence duration (sec);
- Point-to-point Throughput /Recovery – Sofia-Pleven (packets/sec);
- Point-to-point Throughput – Sofia-Plovdiv (packets/sec);
- HTTP – Object Response Time (sec);
- HTTP – Traffic Received (bytes/sec);
- HTTP – Traffic Sent (bytes/sec);
- Voice – Jitter (sec);
- Video conferencing – Packet Delay Variation;
- Video conferencing – Packet End-to-End Delay (sec);
- Video conferencing – Traffic Received (packets/sec);
- Video conferencing – Traffic Sent (packets/sec).

5.1. Network Convergence duration. The convergence time of the two protocols is shown in Figure 7. The main difference between OSPF and EIGRP is seen at the beginning of the graph, after which they almost level off. The average convergence time of OSPF is faster than that of EIGRP. This means that when a change occurs in the OSPF network, the routing table is recalculated and all routers in the area update the topology database by populating the neighbors' LSAs, while in the EIGRP network, routers send queries to direct neighbors to propagate the updated routing table where the successor is recalculated.



Fig. 7. Network Convergence duration (sec)

5.2. Point-to-Point Throughput (packets/sec). Bandwidth is a key parameter for determining the speed at which all data packets are successfully delivered through the network channel. The bandwidth is measured from point to point, in packets/sec. Figure 8 shows the point-to-point bandwidth – from router Sofia to router Pleven. Ten failed connections (failure recovery) with different time intervals were made between the two subnets. Figure 9 shows the bandwidth from router Sofia to router Plovdiv. It is clear from the results between the points in both cases that the EIGRP network has a higher bandwidth than the OSPF network.




Fig. 8. Point-to-Point Throughput – Sofia-Pleven (packets/sec)




Fig. 9. Point-to-Point Throughput – Sofia-Plovdiv (packets/sec)

5.3. HTTP. Through the Application Definition Object, Hypertext Transfer Protocol (HTTP) – heavy browsing – is introduced in both network scenarios. In Figure 10 shows a summary of Object Response Time (sec) and Page Response Time (sec) – for each of the networks – OSPF and EIGRP. In Object Response Time it is reported that the values are very close and the graphs overlap. In Page Response Time – OSPF protocol shows shorter time and better results. In Figures 11 and 12 show Traffic Sent (bytes/sec) and Traffic Received (bytes/sec). At the beginning of the graph, the values in the OSPF and EIGRP networks are close, and then the bytes/sec for the EIGRP network increases and it gives a better result.




Fig. 10. HTTP – Object and Page Response Time (sec)




Fig. 11. HTTP – Traffic Sent (packets/sec)




Fig. 12. HTTP – Traffic Received (packets/sec)

5.4. Voice. With Application Definition Object, Voice – Jitter (sec) is introduced in both network scenarios. Voice flicker is defined as a variation in the delay of the received voice data packets, which affects sound quality as well as data. This constant flow may be uneven or the delay between each package may vary instead of remaining constant. Figure 13 clearly shows a much higher average OSPF network flicker level than with EIGRP.




Fig. 13. Voice – Jitter (sec)

5.5. Video conferencing. Through the Application Definition Object, in both network scenarios, there is Video conferencing, and the

parameters are reported – Packet Delay Variation, Packet End-to-End Delay (sec), Traffic Received (packets/sec), Traffic Sent (packets/sec).

Packet Delay Variation – delay variation is measured by the difference in packet delay. This metric has a huge impact on how video is delivered. Figure 14 shows that the average delay in the two scenarios has very close values. However, EIGRP reflects a slightly higher average packet delay for video traffic, thus having a lower throughput compared to OSPF.




Fig. 14. Video conferencing – Packet Delay Variation

Traffic Sent, Traffic Received – Figures 15 and 16 demonstrate the number of traffic sent and received in both the OSPF and EIGRP networks. The graph shows that a significant difference between the sent and received traffic in OSPF and EIGRP is not observed.




Fig. 15. Video conferencing – Traffic Sent (packets/sec)




Fig. 16. Video conferencing – Traffic Received (packets/sec)

4. Conclusion. Internal dynamic routing protocols OSPF and EIGRP are widely implemented in most network infrastructures. Through this research, a comparative study based on simulation was conducted to indicate which of the above protocols dominates according to specific quantitative indicators. After a thorough review of the literature, the presentation of the characteristics of the two protocols and the execution of the simulation, all the information was critically evaluated and the results of the simulation were collected to indicate which protocol had optimal performance.

Despite claims from other studies that the EIGRP protocol has a faster duration of network convergence than OSPF, the simulation shows that the OSPF protocol has a faster average convergence duration. With the results obtained, the main difference between OSPF and EIGRP is observed at the beginning of the graph, after which there is an alignment.

As a key parameter for determining speed, point-to-point bandwidth measurement, in both cases, shows a better performance of the EIGRP protocol and a correspondingly higher bandwidth.

With HTTP – Heavy browsing, the results for Object Response Time and Page Response Time in both protocols are very close and there is an overlap of the graphics. When comparing the received and sent traffic, it is apparent that the EIGRP protocol is faster.

Voice jitter, as a variation in the delay of received voice data packets, indicates a higher average OSPF protocol flicker level than with EIGRP.

OSPF and EIGRP performance has also been measured based on real-time traffic via video conference. The simulation gives important

information about the parameters of Packet Delay Variation, Packet End-to-End Delay, Traffic Received, and Traffic Sent (packets/sec). The packet delay variation is very similar for the two protocols, but EIGRP reflects a slightly higher average delay and, thus, has a lower throughput compared to OSPF. In end-to-end delay, no significant difference was observed between the performance of OSPF and EIGRP. The results for the received and sent traffic for the two protocols are also close, with slightly higher values for EIGRP.

A transition between the two protocols was also made during the study. OSPF was found to be the more commonly used protocol of this group. This is, on the one hand, due to the fact that EIGRP is a closed protocol and property of CISCO, on the other hand, better performance in some respects. The comparison between the two protocols showed that the combined implementation of EIGRP and OSPF for network routing is to be recommended. Migrating from one protocol to the other can be a procedure that can be addressed in a separate study due to different work scenarios.

The detailed simulation research helps to find the best solution to research questions. Although the objective of this research has been achieved, the limitations of the OPNET Modeler – Edition 14.5 simulation tool should be taken into account. It is therefore difficult to give an unambiguous answer to the question of 'which of the two protocols is the best in terms of performance'. It should be stressed that many factors play a crucial role in choosing the protocol to be used in each case – such as infrastructure, network size and requirements to be met each time. This experiment contributes to the existing knowledge, enriching the research in the field of network protocols and contributing to the selection of the right protocol for the investigated parameters: convergence, speed, point-to-point bandwidth measurement, HTTP – Heavy browsing, Voice jitter and video conference. Based on the obtained result, it is clearly stated that the hardware implementations of the routing protocol are better than using a network simulator. In addition, large network scaling experiments can be conducted to highlight the multiarea in the OSPF routing protocol. Finally, the research can continue with extensive OSPF and EIGRP experiments in IPv6, using professionally applied research.

Future work will include an analysis of the members of IGP (Interior Gateway Protocol) from an energy perspective. In-depth research will be carried out for Greener Internetworking.

References

1. Biradar A.G. A Comparative Study on Routing Protocols: RIP, OSPF and EIGRP and Their Analysis Using GNS-3. 2020 5th IEEE International Conference on Recent

- Advances and Innovations in Engineering (ICRAIE), 2020. pp. 1-5. doi: 10.1109/ICRAIE51050.2020.9358327.
2. Athira M., Abrahami L., Sangeetha R.G. Study on network performance of interior gateway protocols – RIP, EIGRP and OSPF. 2017 International Conference on Nextgen Electronic Technologies: Silicon to Software (ICNETS2), 2017. pp. 344-348. doi: 10.1109/ICNETS2.2017.8067958.
 3. Panagiotopoulou V. Simulation-based Comparative Study of OSPF and EIGRP Routing Protocols. University of Derby, school of computing & mathematics, 2015. doi: 10.13140/RG.2.2.29429.47847.
 4. Kurose J.F., Ross K.W. Computer Networking. 8th edn. Pearson Education, 2020. 957 p.
 5. Medhi D., Ramasamy K. Network Routing: Algorithms, Protocols, and Architectures. 2nd edition. Oxford, U.K.: Elsevier Inc., 2017. p. 1018.
 6. Pei D., Massey D., Zhang L. A formal specification for RIP protocol. UCLA CSD Technical Report TR040046, 2004.
 7. Rakheja P., Kaur P., Gupta A., Sharma A. Performance Analysis of RIP, OSPF, IGRP and EIGRP Routing Protocols in a Network. International Journal of Computer Applications. 2012. vol. 48. pp. 6-11. doi: 10.5120/7446-0401.
 8. Liu Y., Reddy A.L.N. A fast rerouting scheme for OSPF/IS-IS networks. Proceedings. 13th International Conference on Computer Communications and Networks (IEEE Cat. No.04EX969). 2004. pp. 47-52. doi: 10.1109/ICCCN.2004.1401585.
 9. Haas Z.J., Pearlman M.R. The Performance of Query Control Schemes for the Zone Routing Protocol. IEEE/ACM Transactions on Networking (TON), 2001. vol. 9. no. 4. pp. 427-438.
 10. Hinds A., Atojoko A., Zhu S.Y. Evaluation of OSPF and EIGRP Routing Protocols for IPv6. International Journal of Future Computer and Communication. 2013. vol. 2. no. 4. pp. 287-291.
 11. Ferguson D., Moy J. OSPF Version 3. RFC 5340. Sycamore Networks, Inc.
 12. Graziani R., Johnson A. Routing Protocols and Concepts, CCNA Exploration Companion Guide. London: Pearson Education. Companion Guide series, 2008.
 13. Goyal M. et al. Improving Convergence Speed and Scalability in OSPF: A Survey. IEEE Communications Surveys & Tutorials. Second Quarter. 2012. vol. 14. no. 2, pp. 443-463. doi: 10.1109/SURV.2011.011411.00065.
 14. Karna H., Baggan V., Sahoo, A.K., Sarangi P.K. Performance Analysis of Interior Gateway Protocols (IGPs) using GNS-3. 2019 8th International Conference System Modeling and Advancement in Research Trends (SMART). 2019. pp. 204-209. doi: 10.1109/SMART46866.2019.9117308.
 15. Leahy E. EIGRP – Packets & Neighborships. Available at: <http://ericleahy.com/index.php/eigrp-packets-neighborships/>. (accessed 29.04.2022).
 16. FS Community IGRP vs OSPF: What's the Difference? Available at: <https://community.fs.com/blog/eigrp-vs-ospf-differences.html>. 2021. (accessed 26.5.2022).
 17. Tech Differences. Difference between EIGRP and OSPF. Available at: <https://techdifferences.com/difference-between-eigrp-and-ospf.html> (accessed 26.5.2022).
 18. CISCO OSPF Design Guide. Document ID: 7039. Available at: <https://www.cisco.com/c/en/us/support/docs/ip/open-shortest-path-first-ospf/7039-1.html>. 2022. (accessed 20.4.2022).
 19. CISCO Enhanced Interior Gateway Routing Protocol. Document ID: 16406. Available at: <https://www.cisco.com/c/en/us/support/docs/ip/enhanced-interior-gateway-routing-protocol-eigrp/16406-eigrp-toc.html>. 2020. (accessed 26.4.202).

20. Arvind T. A Comparative Study of Various Network Simulation Tools // International Journal of Computer Science & Engineering Technology (IJCSSET). 2016. vol. 7. no. 08. pp. 374-378.
21. Sethi A., Hnatyshin V. The Practical OPNET User Guide for Computer Network Simulation. 1st edn. CRC Press. Available at: <https://www.perlego.com/book/1606584/the-practical-opnet-user-guide-for-computer-network-simulation-pdf> (Accessed: 14 October 2022).
22. Prokkola, J. Simulations and Tools for Telecommunications. OPNET - Network Simulator. (MSc). University of Oulu, 2018.
23. SYSC 4005/5001 SIMULATION AND MODELING. Introduction to Using OPNET Modeler. Available at: http://www.sce.carleton.ca/faculty/lambadaris/courses/5001/opnet_tutorial.pdf (accessed 26.06.2022).
24. Ivanova D., Mitev D. Usability strategy and guidelines for building an accessible web portal. AIP Conference Proceedings. AIP Publishing LLC. 2021. vol. 2333. no. 1.

Tsochev Georgi — Ph.D., Chief assistant, Department of information technologies in industry, Technical University of Sofia. Research interests: computer science, computer networks and communication, neural networks, deep learning, application of mathematics and informatics in cybersecurity. The number of publications — 37. gtsochev@tu-sofia.bg; 8, boulevard Kliment Ohridski, 1000, Sofia, Bulgaria; office phone: +359895589861.

Popova Kristina — Junior researcher, Laboratory of network and information security, Technical University of Sofia. Research interests: network communications, network and information security, artificial intelligence. The number of publications — 1. kpopova@tu-sofia.bg; 8, boulevard Kliment Ohridski, 1000, Sofia, Bulgaria; office phone: +359895589861.

Stankov Ivan — Ph.D., Associate professor, Department of computer systems, Technical University of Sofia. Research interests: computer science, building and management of information systems, IoT, neural networks, deep learning, cybersecurity. The number of publications — 31. istankov@tu-sofia.bg; 8, boulevard Kliment Ohridski, 1000, Sofia, Bulgaria; office phone: +359893690280.

Г.Р. ЦОЧЕВ, К.К. ПОПОВА, И.С. СТАНКОВ
**СРАВНИТЕЛЬНОЕ ИССЛЕДОВАНИЕ МОДЕЛИРОВАНИЕМ
ПРОТОКОЛОВ МАРШРУТИЗАЦИИ OSPF И EIGRP**

Цочев Г.Р., Попова К.К., Станков И.С. Сравнительное исследование моделированием протоколов маршрутизации OSPF и EIGRP.

Аннотация. Компьютерные сети основаны на технологии, обеспечивающей техническую инфраструктуру, в которой протоколы маршрутизации используются для передачи пакетов через Интернет. Протоколы маршрутизации определяют, как маршрутизаторы взаимодействуют друг с другом путем распространения информации. Они используются для описания того, как маршрутизаторы взаимодействуют друг с другом, изучения доступных маршрутов, построения таблиц маршрутизации, принятия решений о маршрутизации и обмена информацией между соседями. Основная цель протоколов маршрутизации — определить наилучший маршрут от источника к месту назначения. Частный случай протокола маршрутизации, работающего в автономной системе, называется протоколом внутренней маршрутизации (IGP — Internal Gateway Protocol). В статье анализируется проблема правильного выбора протокола маршрутизации. Open Shortest Path First (OSPF) и Enhanced Internal Gateway Routing Protocol (EIGRP) считаются ведущими протоколами маршрутизации для приложений реального времени. Для этого их выбирают для изучения. Основной целью исследования является сравнение предложенных протоколов маршрутизации и их оценка на основе различных показателей производительности. Эта оценка осуществляется теоретически — путем анализа их характеристик и действия, и практически — посредством имитационных экспериментов. После изучения литературы определяются сценарии моделирования и количественные показатели, по которым сравнивается производительность протоколов. Во-первых, сетевая модель с OSPF разрабатывается и моделируется с помощью симулятора OPNET Modeler. Во-вторых, EIGRP реализован в том же сетевом сценарии, и выполняется новое моделирование. Реализация сценариев должна собрать необходимые результаты и проанализировать работу двух протоколов. Данные должны быть получены, а оценка и вывод должны быть сделаны в отношении определенных количественных показателей.

Ключевые слова: протоколы маршрутизации, конвергенция, пропускная способность, компьютерные сети, топология сети, OSPF, EIGRP.

Литература

1. Biradar A.G. A Comparative Study on Routing Protocols: RIP, OSPF and EIGRP and Their Analysis Using GNS-3. 2020 5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE), 2020. pp. 1-5. doi: 10.1109/ICRAIE51050.2020.9358327.
2. Athira M., Abrahami L., Sangeetha R.G. Study on network performance of interior gateway protocols – RIP, EIGRP and OSPF. 2017 International Conference on Nextgen Electronic Technologies: Silicon to Software (ICNETS2), 2017. pp. 344-348. doi: 10.1109/ICNETS2.2017.8067958.
3. Panagiotopoulou V. Simulation-based Comparative Study of OSPF and EIGRP Routing Protocols. University of Derby, school of computing & mathematics, 2015. doi: 10.13140/RG.2.2.29429.47847.
4. Kurose J.F., Ross K.W. Computer Networking. 8th edn. Pearson Education, 2020. 957 p.

5. Medhi D., Ramasamy K. *Network Routing: Algorithms, Protocols, and Architectures*. 2nd edition, Oxford, U.K.: Elsevier Inc., 2017. p. 1018.
6. Pei D., Massey D., Zhang L. A formal specification for RIP protocol, UCLA CSD Technical Report TR040046, 2004.
7. Rakheja P., Kaur P., Gupta A., Sharma A. Performance Analysis of RIP, OSPF, IGRP and EIGRP Routing Protocols in a Network. *International Journal of Computer Applications*. 2012. vol. 48. pp. 6-11. doi: 10.5120/7446-0401.
8. Yong L., Reddy A.L.N. A fast rerouting scheme for OSPF/IS-IS networks. *Proceedings. 13th International Conference on Computer Communications and Networks (IEEE Cat. No.04EX969)*. 2004. pp. 47-52. doi: 10.1109/ICCCN.2004.1401585.
9. Haas Z.J., Pearlman M.R. The Performance of Query Control Schemes for the Zone Routing Protocol. *IEEE/ACM Transactions on Networking (TON)*. 2001. vol. 9. no. 4. pp. 427-438.
10. Hinds A., Atojoko A., Zhu S.Y. Evaluation of OSPF and EIGRP Routing Protocols for IPv6. *International Journal of Future Computer and Communication*. 2013. vol. 2. no. 4. pp. 287-291.
11. Ferguson D., Moy J. OSPF Version 3, RFC 5340. Sycamore Networks, Inc., 2008.
12. Graziani R., Johnson A. *Routing Protocols and Concepts, CCNA Exploration Companion Guide*. London: Pearson Education. Companion Guide series, 2008.
13. Goyal M. et al. Improving Convergence Speed and Scalability in OSPF: A Survey. *IEEE Communications Surveys & Tutorials*. Second Quarter. 2012. vol. 14. no. 2. pp. 443-463. doi: 10.1109/SURV.2011.011411.00065.
14. Karna H., Baggan V., Sahoo A.K., Sarangi P.K. Performance Analysis of Interior Gateway Protocols (IGPs) using GNS-3, 2019 8th International Conference System Modeling and Advancement in Research Trends (SMART). 2019. pp. 204-209. doi: 10.1109/SMART46866.2019.9117308.
15. Leahy E. EIGRP – Packets & Neighborships. Available at: <http://ericleahy.com/index.php/eigrp-packets-neighborships/>. (accessed 29.04.2022).
16. FS Community IGRP vs OSPF: What's the Difference? Available at: <https://community.fs.com/blog/eigrp-vs-ospf-differences.html>. 2021. (accessed 26.5.2022).
17. Tech Differences. Difference between EIGRP and OSPF. Available at: <https://techdifferences.com/difference-between-eigrp-and-ospf.html> (accessed 26.5.2022).
18. CISCO OSPF Design Guide. Document ID: 7039. Available at: <https://www.cisco.com/c/en/us/support/docs/ip/open-shortest-path-first-ospf/7039-1.html>. 2022. (accessed 20.4.2022).
19. CISCO Enhanced Interior Gateway Routing Protocol. Document ID: 16406. Available at: <https://www.cisco.com/c/en/us/support/docs/ip/enhanced-interior-gateway-routing-protocol-eigrp/16406-eigrp-toc.html>. 2020. (accessed 26.4.202).
20. Arvind T. A Comparative Study of Various Network Simulation Tools. *International Journal of Computer Science & Engineering Technology (IJCSET)*. 2016. vol. 7. no. 08. pp. 374-378.
21. Sethi A., Hnatyshin V. *The Practical OPNET User Guide for Computer Network Simulation*. 1st edn. CRC Press. Available at: <https://www.perlego.com/book/1606584/the-practical-opnet-user-guide-for-computer-network-simulation-pdf>. 2012. (Accessed: 14 October 2022).
22. Prokkola J. *Simulations and Tools for Telecommunications. OPNET – Network Simulator*. (MSc). University of Oulu, 2008.
23. SYSC 4005/5001 SIMULATION AND MODELING. Introduction to Using OPNET Modeler, Available at:

http://www.sce.carleton.ca/faculty/lambadaris/courses/5001/opnet_tutorial.pdf
(accessed 26.06.2022).

24. Ivanova D., Mitev D. Usability strategy and guidelines for building an accessible web portal, AIP Conference Proceedings. AIP Publishing LLC. 2021. vol. 2333. no. 1.

Цочев Георги Руменов — канд. техн. наук, главный ассистент, департамент информационных технологий в промышленности, Технический университет - София. Область научных интересов: информатика, информационные технологии, нейронные сети, глубинное обучение, киберзащита. Число научных публикаций — 37. gtsochev@tu-sofia.bg; бульвар Климент Охридски, 8, 1000, София, Болгария; р.т.: +359895589861.

Попова Кристина Костадинова — младший научный сотрудник, лаборатория сетевой и информационной безопасности, Технический университет - София. Область научных интересов: сетевые коммуникации, сетевая и информационная безопасность, искусственный интеллект. Число научных публикаций — 1. kropova@tu-sofia.bg; бульвар Климент Охридски, 8, 1000, София, Болгария; р.т.: +359895589861.

Станков Иван Стефанов — д-р техн. наук, доцент, кафедра компьютерных систем, Технический университет - София. Область научных интересов: информатика, построение и управление информационными системами, IoT, нейронные сети, глубокое обучение, кибербезопасность. Число научных публикаций — 31. istankov@tu-sofia.bg; бульвар Климент Охридски, 8, 1000, София, Болгария; р.т.: +359893690280.

А.Д. ОБУХОВ, А.А. ВОЛКОВ, А.О. НАЗАРОВА
**МИКРОСЕРВИСНАЯ АРХИТЕКТУРА ВИРТУАЛЬНЫХ
ТРЕНАЖЕРНЫХ КОМПЛЕКСОВ**

Обухов А.Д., Волков А.А., Назарова А.О. Микросервисная архитектура виртуальных тренажерных комплексов. f

Аннотация. В представленной работе рассматривается задача автоматизации и снижения сложности процесса разработки виртуальных тренажерных комплексов. Проведенный анализ предметной области показал необходимость перехода от монолитного подхода к сервис-ориентированному варианту архитектуры. Выявлено, что использование монолитной архитектуры при реализации виртуальных тренажерных комплексов ограничивает возможность модернизации системы, увеличивает ее программную сложность, затрудняет реализацию интерфейса для управления и мониторинга процесса подготовки. Представлена общая концепция микросервисной архитектуры виртуальных тренажерных комплексов, даны определения основных и второстепенных компонентов. Научная новизна исследования заключается в переходе от классической монолитной архитектуры в предметной области ВТК к микросервисной архитектуре и устранении недостатков данного подхода за счет реализации единого протокола обмена информацией между модулями и отделения процедур сетевого взаимодействия в программные библиотеки в каждом микросервисе для унификации и повышения надежности работы системы. Применение изолированных, слабо связанных микросервисов позволяет использовать оптимальные технологии, платформы и фреймворки для их реализации, отделить графический интерфейс инструктора тренажера от системы визуализации и виртуальной реальности, обеспечить возможность гибкой замены основных компонентов (визуализации, интерфейса, взаимодействия с виртуальной реальностью) без изменения архитектуры и влияния на остальные модули. Осуществлена декомпозиция структурной модели микросервисной архитектуры, представлена специфика функционирования основных компонентов. Рассмотрена реализация библиотек сетевого взаимодействия микросервисов и протокола обмена данными на основе JSON. Практическая значимость предложенной архитектуры состоит в возможности распараллеливания и снижения сложности процесса разработки и модернизации тренажерных комплексов. Проанализированы особенности функционирования систем, реализованных на предложенной микросервисной архитектуре.

Ключевые слова: микросервисная архитектура, микросервисы, виртуальные тренажерные комплексы, межмодульное взаимодействие, оптимизация передачи данных.

1. Введение. Виртуальные тренажерные комплексы (ВТК) включают широкий класс программных, аппаратных и программно-аппаратных систем, направленных на решение задач профессиональной подготовки [1], реабилитации (физической и психологической) [2, 3] и диагностики [4, 5]. Например, ВТК успешно применяются при подготовке шахтеров [6], так как позволяют смоделировать в виртуальной реальности штатные процессы трудовой деятельности и аварийные ситуации (пожаротушение, эвакуация после

затопления, обрушение, задымление). Современные ВТК основываются на передовых технологиях визуализации, сбора, анализа и обработки информации, включая следующие:

- технологии дополненной (AR) и виртуальной (VR) реальности для погружения пользователя в цифровое пространство [7];
- нейронные сети и машинное обучение для решения задач анализа, обработки и управления [8];
- компьютерное зрение для отслеживания состояния окружающей среды, объектов наблюдения, пользователя, процессов, протекающих в предметной области [9];
- имитационное оборудование для моделирования воздействия на органы чувств человека, создания физических нагрузок [10];
- медицинское оборудование для отслеживания текущего состояния пользователя [11].

При разработке ВТК с реализацией вышеперечисленных технологий, интеграцией дополнительных модулей и оборудования неизбежно возрастет программная сложность системы и возникает потребность в привлечении большого количества человеческих ресурсов [12]. Реализация ВТК как монолитного проекта имеет определенные преимущества для небольших команд разработчиков и систем с ограниченным количеством связей между модулями. С другой стороны, высокая связность компонентов ограничивает модернизацию и внедрение новых технологий, добавление, удаление или изменение модулей. Со временем общая программная база расширяется и становится громоздкой, а структура слишком тяжелой для понимания, что приводит к сложности поддержки [13]. Кроме того, существуют значительные сложности с реализацией интерфейса для инструктора тренажерного комплекса. Этот модуль должен быть реализован отдельно от системы визуализации, но постоянно обмениваться с ней информацией, что даже в условиях монолитной архитектуры приводит к реализации нескольких связанных модулей или даже отдельных проектов.

Таким образом, для устранения обозначенных недостатков при реализации ВТК, обладающих высокой сложностью, необходимо осуществить переход к новой архитектуре – сервис-ориентированной, в которой система разделяется на множество отдельных модулей (сервисов), слабо связанных между собой стандартизированными протоколами, легко заменяемых, решающих отдельные конкретные задачи [14]. Каждый модуль самодостаточен и независим, поэтому можно изменять фрагменты ВТК, не затрагивая остальные элементы

системы, распределять сервисы по разным серверам, реализовывать их на разных языках программирования и с применением различных технологий.

Среди сервис-ориентированных архитектур можно выделить направление микросервисных архитектур [15, 16], где приложение состоит из множества небольших сервисов, взаимодействующих между собой (чаще всего по протоколу HTTP). Каждый микросервис самодостаточен и независим, поэтому можно изменять только фрагменты ВТК, не затрагивая остальные элементы системы, распределять сервисы по разным серверам, реализовывать их на разных языках программирования и с применением различных технологий. На практике существует несколько стилей (стандартов) разработки приложений в соответствии с микросервисной идеологией, среди которых можно выделить REST (REpresentational State Transfer) [17]. REST – это архитектурный стиль программного обеспечения, включающий набор правил и ограничений на механику взаимодействия сервера и клиента в сети, основанный на использовании существующих стандартов: HTTP, URL, JSON, XML и других.

Достоинствами микросервисной архитектуры для предметной области ВТК являются [18]:

- масштабируемость приложений: добавление новых функций может быть реализовано через новый сервис, а удаление – через отключение ненужных сервисов;
- распределение задач: каждый сервис – это отдельный небольшой проект, который можно реализовать на любой платформе или языке программирования в соответствии с теми задачами, которые он решает;
- безопасность: сервисы изолированы и обмениваются данными по API, что позволяет обеспечить доставку только корректной информации;
- распределение ресурсов на каждый сервис: часть сервисов может требовать большой вычислительной нагрузки, часть – больших объемов памяти, тогда можно разместить их на разных серверах, ориентируясь на потребности каждого сервиса;
- безопасность отладки: поиск и исправление осуществляется в рамках изолированного от остальных компонентов модуля, что исключает возможность нарушения работы всей системы в процессе отладки;
- снижение степени зацепления: разделение проекта на изолированные, решающие конкретные задачи модули позволяет

снизить уровень зависимости между ними, упростить логику модулей, их тестирование и модернизацию;

– повышение связности: изолированность и фокус на решении узкого класса задач в рамках каждого микросервиса позволяет обеспечить высокую взаимосвязанность элементов внутри модуля, обеспечить их соответствие главной цели микросервиса.

Среди известных недостатков микросервисной архитектуры стоит выделить следующие: сложность тестирования из-за сложных маршрутов передачи информации между различными модулями, необходимость согласованности информации из-за задержки при передаче данных; рост объема передачи информации [19–21].

Проведенный анализ существующих решений, построенных на основе микросервисной архитектуры, показал, что многие крупные компании в сфере информационных технологий в последние годы осуществили переход от монолитной архитектуры к микросервисам (Amazon, eBay, Netflix, Spotify, Walmart и другие). Это позволило им реализовывать кроссплатформенные высоконагруженные, устойчивые сервисы. Положительный эффект от подобного перехода отмечается во многих отраслях, например, в ходе опроса 10 компаний из отраслей информационных технологий, торговли, логистики и туризма [22]. Выяснено, что влияние микросервисов на качество и поддержку программного обеспечения оценено как положительное в исследовании [23] на основе опроса 52 специалистов из банковской сферы, ИТ-индустрии и разработки программного обеспечения. Положительный эффект отмечен в сфере образования при реализации информационных систем для тестирования, обучения, автоматизации внутренних процессов университетов [24]. В настоящее время микросервисная архитектура в предметной области ВТК не применялась, однако ввиду обозначенных ранее преимуществ данный подход является перспективным направлением.

Таким образом, задача исследования состоит в необходимости разработки микросервисной архитектуры для ВТК, учитывающей влияние вышеперечисленных недостатков и реализующей все обозначенные достоинства для автоматизации и снижения сложности синтеза систем различного масштаба, обеспечения высокой связности и снижения степени зацепления программного кода.

2. Концепция микросервисной архитектуры ВТК. На основе проведенного литературного обзора и выявленных преимуществ микросервисного подхода к построению архитектуры информационных систем сформулирована концепция микросервисной

архитектуры ВТК (рисунок 1). В рамках разработанной архитектуры будем использовать следующие понятия.

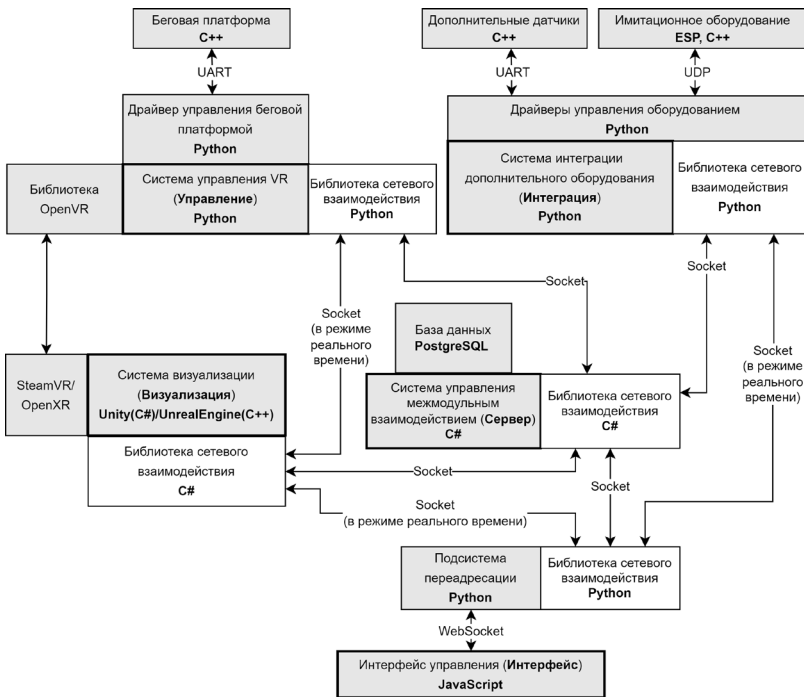


Рис. 1. Структурная модель микросервисной архитектуры ВТК

Микросервисная архитектура – сервис-ориентированная структура информационной системы, при которой осуществляется декомпозиция единого проекта на набор модулей с низким зацеплением и высоким уровнем внутренней связности.

Тогда для предметной области ВТК микросервисная архитектура должна обеспечивать выполнение следующих принципов, что позволит декомпозировать изначально монолитную архитектуру ВТК на набор микросервисов [25]:

– системный анализ объектов предметной области: необходимо осуществить анализ предметной области для последующего формализации моделей объектов и их программных абстракций, которые являются функциональной и структурной основой каждого микросервиса;

– изолированность: обеспечение независимости и автономности каждого микросервиса за счет инкапсуляции деталей его реализации от остальных компонентов системы, недопустимость выполнения отдельных функций или копирования элементов одного модуля в других микросервисах;

– автоматизация типовых процессов: использование унифицированных протоколов обмена информации, инструментов сетевого взаимодействия, средств тестирования и отладки, протоколирования;

– децентрализация процесса разработки: каждый микросервис должен разрабатываться независимо, принятие решений относительно программной реализации модуля осуществляется его разработчиками без внешнего согласования;

– прозрачность процесса разработки: наличие и использование эффективного инструментария для протоколирования, тестирования и отладки для обеспечения высокой скорости разработки и модернизации, возможности оперативного устранения неполадок.

Под термином *Система управления межмодульным взаимодействием* (Сервер) будем понимать обязательный микросервис архитектуры, реализующий функциональность сервера в ВТК, отвечающий за координацию остальных модулей, управление каналами связи и организацию передачи данных между модулями, работу с БД, хранение и обработку информации о процессе обучения и взаимодействия с виртуальной средой [26].

Под термином *Интерфейс управления* (Интерфейс) будем понимать обязательный микросервис архитектуры, реализующий процесс управления ВТК через графическую оболочку и следующую функциональность: авторизация пользователей, формирование ВТК (за счет компоновки из множества подключенных в сеть микросервисов), запуск тренировки, ее мониторинг и протоколирование.

Под термином *Система визуализации* (Визуализация) будем понимать обязательный микросервис архитектуры, отвечающий за визуальное представление виртуального пространства ВТК пользователю с использованием различных игровых трехмерных движков и фреймворков, включая работу с SteamVR или OpenXR для поддержки устройств виртуальной реальности.

Под термином *Система управления VR* (Управление) будем понимать обязательный микросервис архитектуры, обеспечивающий подключение, мониторинг и интеграцию компонентов VR (контроллеров, трекеров) для организации взаимодействия с

виртуальной средой и перемещения пользователя в сцене (в том числе, с помощью активных беговых платформ [27]).

Под термином *Система интеграции дополнительного оборудования* (Интеграция) будем понимать набор дополнительных микросервисов, реализующих управление и сбор данных с интегрированного в ВТК имитационного оборудования, дополнительных датчиков по проводным и беспроводным протоколам для повышения качества подготовки или сбора дополнительных данных о состоянии обучаемого.

Далее рассмотрим специфику реализации и функционировании каждой из сущности в рамках микросервисной архитектуры ВТК, так как разделение обозначенных компонентов, ранее тесно интегрированных между собой в монолитной архитектуре, неизбежно придет к значительным изменениям. Итак, определены 4 обязательных микросервиса и один вспомогательный, отражающий возможность функционального расширения архитектуры за счет применения различного имитационного оборудования и дополнительных датчиков. Разделение обозначенных сущностей на отдельные микросервисы позволило, с одной стороны, расширить их функциональность за счет возможности использования произвольных программных платформ, языков программирования и фреймворков, однако привело к необходимости их модернизации.

Микросервис Сервер реализуется на высокопроизводительных языках программирования, так как от его быстродействия напрямую зависит производительность работы всего ВТК. Необходимо отметить, что в отличие от сервис-ориентированной архитектуры, где каждый модуль системы связан с общим модулем интеграции, в микросервисной предполагается прямая связь модулей друг с другом и горизонтальная иерархия всех составляющих системы. В том случае, если одному модулю требуется постоянно обмениваться информацией с другим модулем, не оказывая на Сервер лишнюю нагрузку, то он может организовать с ним прямое подключение. В результате Сервер выполняет роль маршрутизатора, управляет доступом, обрабатывает ошибки, а также ведет записи в централизованном журнале. Связь модулей с Сервером и между собой оформлена в виде архитектуры клиент-сервер, в которой любой микросервис должен хранить состояние подключенных клиентов и выполняемых с ними процедур. Каждый микросервис обменивается с другими сообщениями, которые могут содержать данные, команды, события, ошибки, либо являться частью процедур. Помимо маршрутизации и контроля состояний всех

компонентов ВТК, Сервер отвечает за хранение и обработку информации из базы данных и их передачу другим микросервисам.

Микросервис Интерфейс реализует взаимодействие пользователя с ВТК. При использовании игровых движков разработка интерфейса приводит к значительному усложнению проекта, особенно, когда виртуальная сцена транслируется в системы виртуальной реальности. Кроме того, при организации процесса обучения требуется обеспечить контроль со стороны инструктора, что требует отдельного интерфейса. Поэтому полное отделение виртуальной сцены от интерфейса ее управления позволяет значительно упростить процесс разработки. Отделение интерфейса от остальных микросервисов дает возможность удаленного управления несколькими ВТК, быстрое переподключение между ними, отслеживание ошибок от всех остальных микросервисов. Интерфейс получает всю информацию от Сервера, но также может устанавливать подключение типа «клиент-клиент» с другими микросервисами (также при участии Сервера). Для обеспечения кроссплатформенности модуля Интерфейса его реализация предлагается в качестве Web-приложения на основе двух языков программирования: Python (для использования унифицированной системы сетевого взаимодействия на основе TCP-сокетов) и JavaScript (для реализации взаимодействия с интерфейсом и его динамического формирования на основе концепции Активностей). Передача информации внутри микросервиса между двумя составляющими осуществляется посредством технологии WebSocket. Концепция Активностей (Activity) заключается в повторном использовании программного кода логики и компонентов интерфейса, реализации жизненного цикла страницы, аналогично принятой в операционной системе Android при разработке приложений.

Микросервис Визуализация тесно взаимодействует с модулем Управление. За счет отделения визуальной составляющей (трёхмерные объекты, виртуальное пространство, эффекты, интерактивное взаимодействие) непосредственно от логики работы с аппаратным обеспечением VR (подключение и мониторинг контроллеров и датчиков движения, реализация системы перемещения с помощью сторонних платформ) был достигнут следующий положительный эффект: модуль Визуализация может быть реализован на базе любых игровых движков и сред разработки, в свою очередь, микросервис Управление может использовать в своей основе любой аппаратный комплекс для организации перемещения пользователя. Данные подсистемы, несмотря на тесную и совместную работу, являются

полностью заменимыми на аналоги, что не приведёт к изменению в логике работы каждого из них. Кроме того, логика непосредственного взаимодействия с аппаратным обеспечением различных платформ вынесена отдельно, а в микросервисе Управление посредством драйвера предоставляется высокоуровневый API для передачи управляющих команд и отслеживания состояния, что также позволяет повысить гибкость работы данного модуля.

Микросервисы категории Интеграция хотя и являются дополнительными, позволяют значительно расширить функциональные возможности профессиональной подготовки с использованием ВТК. Приведем примеры таких микросервисов. В рамках предыдущих исследований в качестве подобного модуля успешно выступала имитационная система изолирующих дыхательных аппаратов [23]. Для данного типа оборудования также требуется разработка специализированных драйверов, представляющих высокоуровневые функции для управления и мониторинга состояния. Связь с оборудованием может быть организована как проводным, так и беспроводным способом. Помимо имитационного оборудования в качестве микросервиса Интеграции могут выступать различные медицинские датчики (пульсоксиметры, энцефалографы, электромиографы и так далее), что позволяет осуществить сбор дополнительных данных о состоянии обучаемого в процессе выполнения упражнений в виртуальной реальности.

Таким образом, одним из ключевых моментов научной новизны предложенной архитектуры является возможность гибкой замены основных компонентов без изменения архитектуры и влияния на остальные модули, возможность расширения архитектуры за счет добавления новых микросервисов. Разделение общей структуры тренажерного комплекса на отдельные микросервисы в соответствии с теми задачами, которые они решают, значительно повышает связность (за счет ориентирования микросервиса на одну конкретную задачу) и снижает степень зацепления (микросервисы независимы между собой). Следующая важная составляющая микросервисной архитектуры ВТК – это организация процесса взаимодействия модулей.

3. Процедура сетевого взаимодействия микросервисов ВТК.

Недостатком микросервисной архитектуры является требование к высокой надежности и корректности процесса обмена данными между модулями, так как в отличие от монолитной архитектуры объем передаваемой информации между компонентами возрастает в несколько раз. Для решения данной проблемы и обеспечения высокой надежности функционирования ВТК на основе микросервисной

архитектуры предлагается реализация отдельных программных компонент – библиотек сетевого взаимодействия, разграничивающих функции обмена и передачи информации между микросервисами. Определим основные функциональные возможности данных библиотек:

- формирование набора абстракций, формализующих все основные сущности ВТК;
- механизм десериализации сетевых пакетов, в сущности, программных абстракций объектной модели и сериализации сущностей в пакеты для передачи по сети;
- механизм передачи и приема сетевых пакетов с возможностью проверки целостности и корректности получаемых данных;
- реализация основных методов API, общих для всех микросервисов;
- реализация общих процедур, регламентированных протоколом управления, включая обнаружение Сервера в локальной сети, установку соединения с Сервером и с другими клиентами, штатное закрытие соединения и т.д.;
- ведение журнала событий модуля в едином для всей системы формате и управление параметрами журналирования;
- обработка ошибок в едином пространстве ошибок всей системы;
- управление конфигурацией модуля на основе унифицированного формата конфигурационных файлов;
- процедура загрузки модуля.

Рассмотрим один из вариантов структурной модели библиотеки, отвечающий заданным требованиям. Объектная модель системы представляет собой набор классов, инкапсулирующих все основные сущности (программные абстракции) внутри тренажерного комплекса, такие как: информация о модуле (подсистеме), состояние подключения, ошибка, объект команды и объект события, пользователь, тренажер, тренировка, сессия пользователя и т.д. Классы модели должны предоставлять все базовые методы для работы с сущностями: чтение и запись данных, сравнение, преобразование одних объектов в другие (если это предполагается API), валидацию данных и т.д. Также классы модели должны предоставлять возможность преобразования сущностей из формата, стандартного для используемого языка программирования в формат модели и обратно.

Организация функционирования межмодульного взаимодействия в микросервисной архитектуре заключается в строгой

унификации управляющего протокола и требует единого плана обработки любых запросов от других модулей. При таком подходе каждый микросервис включает в себя, кроме заданной функциональности, еще и реализацию модуля обмена сообщениями. Структура сообщений, которые будут пересылаться между элементами системы, имеет стандартизованную классификацию типов сообщений. В зависимости от типа сообщения определяется соответствующая структура вложенных объектов.

Далее рассмотрим реализацию унифицированного протокола обмена данными между микросервисами ВТК, основанную на использовании формата данных JSON. В качестве основного пакета внутри ВТК используется сущность «Сообщение» («message») (рисунок 2). Сообщение включает в себя ряд заголовков, содержащих различную служебную информацию, а также основной объект с полезной нагрузкой. Заголовки содержат информацию об отправителе и получателе пакета, типе этого пакета, а также несколько дополнительных идентификаторов, требуемых протоколом API (рисунок 2а).

<p>а) Общесистемный пакет</p> <pre>"Message": { "message_type": "#тип сообщения "src": "#источник сообщения "dst": "#цель сообщения "datetime": "#время отправки сообщения "request_id": "#id запроса "session_id": "#id сессии "payload": "#вложенный объект }</pre>	<p>б) payload для типа пакета "command"</p> <pre>"payload": { "args": null, "name": "unity.getScenesList" }</pre>
<p>в) Общий пакет для подтверждения успешного выполнения команды</p> <pre>{ "payload": {}, "message_type": "ack", "src": { "agent_name": "motion-control", "agent_id": "b9f25439-11d5-41a7-9a9c-74a8ca2a7645" }, "dst": { "agent_name": "server", "agent_id": "547e1bba-fc92-44a2-b4be-98162ea6955c" }, "datetime": 1651220209523, "request_id": 0, "session_id": "8e52a262-790f-4c94-9101-ea8b42b30484" }</pre>	<p>г) Общий пакет ошибки</p> <pre>{ "payload": { "code": 13, "description": "Access denied", "cause": { "code": 13, "description": "System.NullReferenceException: Object reference not set to an instance of an object.", "cause": null } }, "message_type": "error", "src": { "agent_name": "unity", "agent_id": "50dd11df-3d0f-470f-b5fe-d9a92538f449" }, "dst": { "agent_name": "server", "agent_id": "547e1bba-fc92-44a2-b4be-98162ea6955c" }, "datetime": 1651220604575, "request_id": 0, "session_id": "e17baed2-7c3b-4954-905d-7898938c7d3e" }</pre>

Рис. 2. Примеры основных типов пакетов

Тип пакета определяет категорию сообщения. В зависимости от типа сообщения модули делегируют обработку соответствующей подсистеме:

- discovery – обнаружение Сервера в локальной сети;
- initialization – подключение клиентов к Серверу и друг к другу;
- disconnect – отключение клиентов от Сервера и друг от друга;
- ack – подтверждение выполнения запроса/команды;
- command – команда;
- data – пакет с данными;
- event – системное событие;
- error – сообщение об ошибке.

Каждый микросервис содержит собственный модуль обработки сообщений, в который сообщение будет отправлено после десериализации. Первым этапом обработки принятого сообщения является Firewall, в котором проверяется необходимость получения сообщения. Вторым этапом является его проверка на соответствие текущим актуальным для модуля процедурам. В том случае, если сообщение корректно, выполняются команды, соответствующие данному этапу процедуры, далее состояние процедуры меняется, генерируется сообщение-ответ и обработка сообщения завершается на этом этапе, иначе сообщение отправляется на следующий этап обработки. На третьем этапе в соответствии с типом сообщения выполняется система команд, в результате будет сгенерирован ответ или ошибка при невозможности выполнения команды. В заключительном четвертом этапе сгенерированный ответ будет отправлен запустившему цепочку действий микросервису.

Прием и передача пакетов реализуются в соответствии с протоколами обмена «клиент-сервер» и «клиент-клиент». Классы подсистемы обмена сообщениями предоставляют высокоуровневый интерфейс для отправки и получения сообщений, позволяющий скрывать детали реализации сетевого обмена. Выполнение базовых процедур, таких как подключение и отключение от других узлов сети также реализуется в рамках подсистемы обмена сообщениями. Обработка основных команд, общих для всех модулей, выполняется в базовом классе обработчика команд.

Рассмотрим систему запрос-ответ на Сервере. В случае получения сообщения типа «command» Сервер десериализует объект payload и распознает тип команды. Для определения функциональности команды разработана классификация команд,

которые делятся на группы в зависимости от специфики модуля. Полное имя команды формируется из имени группы и предназначения команды в группе, например, «group.action». Структура объекта payload для типа «command» представлена на рисунке 2б.

После получения сообщение перенаправляется в метод-обработчик соответствующей команды, где опционально может быть получена дополнительная информация из объекта payload. Далее выполняется запрошенное действие и отправляется результат выполнения команды. Структура подтверждения команды представлена на рисунке 2в.

Если модуль, получивший любой запрос, не может успешно его выполнить, то модулю, отправившему запрос, будет возвращено сообщение с соответствующей ошибкой. Система ошибок унифицирована и разделяется на несколько логических групп, заданных для каждого микросервиса. Структура общего пакета ошибки представлена на рисунке 2г.

Для согласования работы модулей при выполнении простых запросов (команды, ошибки, события и т.д.) либо процедур используется поле «request_id» основного пакета «message». Значение данного поля заполняется любым узлом сети при инициации запроса. Модуль, генерирующий запрос другому модулю отправляет сообщение с определенным значением «request_id» и ожидает ответа с таким же значением данного поля.

Таким образом, решена задача организации межмодульного взаимодействия в микросервисной архитектуре за счет реализации единого протокола обмена информацией и отделения процедур сетевого взаимодействия в программные библиотеки в каждом микросервисе для унификации и повышения надежности работы системы. Это также сказывается на общей сложности ВТК, так как сетевые библиотеки модернизируются и поддерживаются отдельно, а разработчики микросервисов используют для взаимодействия модулей готовые решения.

4. Оптимизация межмодульного взаимодействия микросервисов. Выявленные в ходе анализа предметной области недостатки микросервисной архитектуры (большой объем передаваемой информации и высокие требования к скорости ее передачи для обеспечения согласованной работы всех модулей) приводят к необходимости оптимизации процесса межмодульного взаимодействия в рамках предложенной архитектуры для обеспечения высокой пропускной способности и низких задержек при передаче данных. Эта задача становится особенно актуальной, когда данные

необходимо обрабатывать в реальном времени, например, при передаче данных о положении пользователя из микросервиса Управления в Визуализацию.

Для постановки задачи оптимизации межмодульного взаимодействия микросервисов необходимо рассмотреть основные метрики и параметры данного процесса, а также область их возможных значений.

Пропускная способность канала C (байты в секунду): $C = I/Tt$, где I – объем переданной информации, Tt – время этой передачи. Ввиду естественных ограничений, значение C всегда неотрицательное, $C \geq 0$.

Доля активного времени центрального процессора (ЦП) L (проценты): $L = Ta/Tr \times 100\%$, где Ta – активное время, затраченное на обработку пакета данных, Tr – общее время приема сообщений. Значения L находятся в диапазоне $0\% \leq L < 100\%$, причем значение в 100% является недопустимым, так как в этом случае система не успевает обработать все полученные данные, следовательно, теряет пакеты.

Объем приемного буфера сообщений в оперативной памяти (ОЗУ) $V \rightarrow \min$. Значения V являются целочисленными и кратными степени 2, в рамках данной работы ограничены 32 мегабайтами: $8 \leq V < 32 \times 2^{20}$ (байт).

Доля больших (более 16 КБ) пакетов D (проценты): $D = NL/N \times 100\%$, где NL – число больших пакетов, N – общее число пакетов на протяжении одного сеанса обмена данными. Значения D находятся в диапазоне от 0 до 100% .

Таким образом, основной варьируемой переменной является размер буфера V , который будет напрямую влиять на метрики C и L , в качестве дополнительного входного параметра может использоваться значение D , которое будет отражать специфику передаваемых данных.

В формализованном виде постановка задачи оптимизации будет иметь вид: необходимо найти такой размер приемного буфера V и долю больших пакетов D , при которых целевые функции пропускной способности канала и доли активного времени ЦП стремятся к экстремальным значениям:

$$C(V, D) = I/Tt \rightarrow \max,$$

$$L(V, D) = Ta/Tr \times 100\% \rightarrow \min,$$

при выполнении ограничений:

$$C \geq 0, 0\% \leq L < 100\%, 8 \leq V < 32 \times 2^{20}, 0\% \leq D \leq 100\%.$$

Для решения задачи оптимизации необходимо выявить взаимосвязь между критериями и варьируемыми переменными. Поскольку современные вычислительные комплексы и операционные системы не предоставляют пользователю непосредственного контроля над ресурсами системы, выявить такие закономерности аналитически не представляется возможным из-за большого количества факторов (например, динамически изменяемая тактовая частота ЦП, алгоритмы работы планировщика операционной системы). Наиболее подходящим способом выявления взаимосвязей в данных условиях является вычислительный эксперимент.

Для проведения такого эксперимента в библиотеку сетевого взаимодействия добавлен алгоритм измерения времени приема пакета, подсистема для генерации тестового набора данных и программа для замера метрик C и L . При проведении эксперимента переменная V изменялась по всей области определения по экспоненциальному закону с интервалом в 4 шага на 1 порядок (в двоичной системе счисления). Переменная D варьировалась от 0 до 100% линейно с шагом в 10%. В результате проведения эксперимента получена таблица из 803-х значений. Замеры производились на следующем оборудовании: Intel I7 3770k (4 ГГц), 32Гб ОЗУ, использовался интерпретатор Python 3.8.

В результате отдельно рассмотрим две ситуации (рисунок 3): при отсутствии пакетов большой величины ($D = 0\%$) и при обмене только большими пакетами ($D = 100\%$). Для первого случая получено, что из Парето-оптимального множества буфер размером порядка $V = 32$ КБ является оптимальным. При обмене большими пакетами во втором случае требуется буфер $V = 1$ МБ. Как можно увидеть из графиков, Парето-оптимальные решения для обоих случаев не совпадают. Получено, что среди множества возможных вариантов решения не существует наиболее оптимальной комбинации входных переменных, пригодных для всех возможных вариантов использования. Высокая скорость передачи данных и низкие задержки достигаются только на достаточно большом размере буфера. С другой стороны, это негативно влияет на объем потребляемой ОЗУ.




Рис. 3. Анализ метрик при различных размерах буфера V

В рамках данного исследования предлагается разделить каналы передачи данных между микросервисами на две категории, соответствующие наличию и отсутствию больших пакетов. Первая категория использует буфер, равный 32Кб, вторая – 1Мб. Тогда получим следующее решение задачи оптимизации: для буфера 32Кб $C = 51.4$ Мб/с, $L = 18\%$, для буфера 1Мб $C = 118$ Мб/с, $L = 6\%$.

Определенные в ходе решения задачи значения буфера обеспечивают наименьшую загрузку ЦП и наивысшую скорость среди области Парето. Примером связи первой категории являются Управление-Визуализация (передаются только управляющие команды и сведения о состоянии), второй – Визуализация-Сервер (передается полный протокол тренировки, список сцен с изображениями и описанием). В дальнейшем возможно использование адаптивного алгоритма выбора буфера, подстраивающего его размер под конкретную межмодульную связь.

5. Специфика функционирования ВТК, построенных на микросервисной архитектуре. Функционирование ВТК, реализованного в соответствии с микросервисной архитектурой, значительно отличается от проектов, выполненных по монолитному принципу. Компоненты системы могут быть как распределены между различными терминалами, так и запускаться на одном компьютере. Поэтому одним из важнейших процессов при функционировании системы является процедура инициализации всех микросервисов и объединение их в единую связанную структуру.

Процесс инициализации начинается с запуска всех микросервисов. Каждый из клиентских модулей запускает процедуру обнаружения Сервера в локальной сети. После обнаружения Сервера с ним устанавливается соединение, сначала на статически заданном порту, а затем на динамически выделенном (чтобы освободить статический порт для других клиентов). Изначально Сервер отвечает на запросы обнаружения только модулю Интерфейса. После подключения Интерфейса к Серверу пользователь проходит процедуру авторизации и может либо создать новый тренажер, либо выбрать существующий (в зависимости от прав доступа). После выбора тренажера сервер начинает отвечать на входящие запросы обнаружения всем клиентам, участвующим в работе этого тренажера.

Собранный тренажер сохраняется в базу данных для последующего быстрого запуска. В случае наличия всех микросервисов в системе пользователь может перейти к тренировке: выбрать доступные сцены, отправленные через Сервер микросервисом Визуализация, задать необходимые настройки трекеров или контроллеров посредством компонента Управление и дополнительного оборудования в микросервисе Интеграция. Далее пользователь через Интерфейс запускает тренировку.

В процессе прохождения тренировки Визуализация отправляет в Интерфейс данные о скорости перемещения пользователя, его действиях и ошибках. Также все микросервисы могут оповестить Сервер об ошибках в их работе, что будет отражено в Интерфейсе. После завершения тренировки все данные сохраняются в базу данных в виде протокола и могут быть проанализированы в дальнейшем.

Реализация ВТК для подготовки шахтеров в соответствии с микросервисной архитектурой представлена на рисунке 4. Микросервис Интерфейс (рисунок 4а) обеспечивает удаленное управление и мониторинг ВТК через веб-браузер. Микросервис Визуализация (рисунок 4б) на основе Unity включает виртуальное окружение и оборудование шахты, а также реализует штатные и

аварийные процессы. Микросервисы Управление и Интеграция (рисунк 4в) представлены управляемой беговой дорожкой и имитатором дыхательных аппаратов.

Таким образом, предложенный подход позволит декомпозировать структуру ВТК на отдельные микросервисы, тем самым повысив его гибкость, масштабируемость и возможность модернизации. Предложенное разделение на микросервисы позволяет реализовать их на оптимальных платформах, языках программирования, технологиях и фреймворках, эффективно распределить трудоемкость между разработчиками, тем самым снизив общую сложность проекта. Применение унифицированного протокола передачи данных, сетевых библиотек для организации междомдульного взаимодействия, а также оптимизация размера буфера при передаче информации позволяет минимизировать известные недостатки микросервисных архитектур и в полной мере реализовать их достоинства.

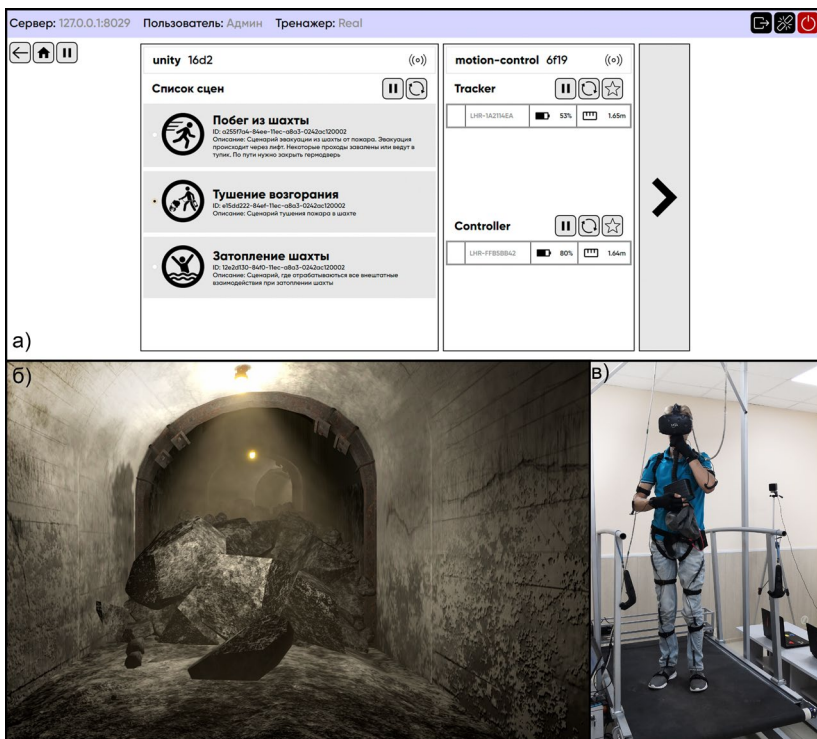


Рис. 4. Пример ВТК, реализованного на основе микросервисной архитектуры

6. Заключение. В работе рассмотрена микросервисная архитектура тренажерных комплексов, ее декомпозиция, особенности организации межмодульной связи и функционирования. Анализ специфики микросервисных архитектур выявил ряд достоинств и недостатков данного подхода, которые были учтены при адаптации данной архитектуры к предметной области ВТК. Предлагаемый подход позволяет разработчикам уйти от монолитного приложения, что повышает гибкость системы в плане модификации, ее расширяемость и стабильность, так как аварийное завершение одного из сервисов может быть корректно обработано остальными компонентами архитектуры (в том числе, с возможностью перезапуска или восстановления отдельных сервисов).

Реализованная в соответствии с предложенной микросервисной архитектурой система управления ВТК имеет ряд особенностей, связанных с распределением функциональности по отдельным узлам и необходимостью реализацией постоянного обмена информацией между ними. Предлагаемая архитектура может использоваться для реализации тренажеров различных масштабов. Научная новизна предложенной микросервисной архитектуры заключается в переходе от классической монолитной архитектуры при синтезе тренажерных комплексов к использованию изолированных, слабо связанных микросервисов; реализации единого протокола обмена информацией между модулями; отделении процедур сетевого взаимодействия в программные библиотеки в каждом микросервисе для унификации и повышения надежности работы системы; возможности гибкой замены основных компонентов без изменения архитектуры и влияния на остальные модули. Также предложенная архитектура решает распространенную проблему реализации графического интерфейса инструктора тренажера, так как изначально отделяет интерфейс в отдельный модуль от системы визуализации.

Рассмотрена реализация библиотек сетевого взаимодействия микросервисов и унифицированного протокола обмена данными на основе JSON. Поставлена и решена задача оптимизации размера буфера для максимизации пропускной способности канала передачи данных между микросервисами и снижения нагрузки на центральный процессор. Предлагаемый подход позволяет снизить вероятность возникновения ошибок на уровне сетевого взаимодействия и обмена сообщениями между микросервисами, а также поддерживать API в актуальном состоянии во всех модулях, основанных на библиотеке.

Представлена специфика функционирования тренажерного комплекса на основе микросервисной архитектуры и приведены

преимущества микросервисной концепции в виде снижения программной сложности и возможности распределения вычислительной нагрузки. В соответствии с изложенной архитектурой реализован ВТК для подготовки шахтеров, обладающий следующими преимуществами: изолированный интерфейс управления для оператора, интеграция управляемой беговой дорожки для перемещения в виртуальной реальности и иного дополнительного оборудования (имитатор дыхательных аппаратов). В ходе дальнейших исследований планируется расширение функциональных возможностей архитектуры за счет добавления новых микросервисов, дальнейшая оптимизация процессов передачи информации, в том числе, за счет адаптивного буфера.

Литература

1. Zahabi M., Abdul Razak A.M. Adaptive virtual reality-based training: a systematic literature review and framework // *Virtual Reality*. 2020. vol. 24. no. 4. pp. 725-752.
2. Saldana D. et al. Applications of head-mounted displays for virtual reality in adult physical rehabilitation: a scoping review // *The American Journal of Occupational Therapy*. 2020. vol. 74. no. 5. pp. 7405205060p1-7405205060p15.
3. Jerdan S.W. et al. Head-mounted virtual reality and mental health: critical review of current research // *JMIR serious games*. 2018. vol. 6. no. 3. pp. e9226.
4. Zulueta A. et al. Virtual reality-based assessment and rating scales in ADHD diagnosis // *Psicología Educativa. Revista de los Psicólogos de la Educación*. 2019. vol. 25. no. 1. pp. 13-22.
5. Alcañiz M. et al. Eye gaze as a biomarker in the recognition of autism spectrum disorder using virtual reality and machine learning: A proof of concept for diagnosis // *Autism Research*. 2022. vol. 15. no. 1. pp. 131-145.
6. Obukhov A.D. et al. The study of virtual reality influence on the process of professional training of miners // *Virtual Reality*. 2022. pp. 1-25
7. Drossis G., Birliraki C., Stephanidis C. Interaction with immersive cultural heritage environments using virtual reality technologies // *International Conference on Human-Computer Interaction*. Springer, Cham. 2018. pp. 177-183.
8. Shinde P.P., Shah S. A review of machine learning and deep learning applications // *2018 Fourth international conference on computing communication control and automation (ICCUBEA)*. IEEE. 2018. pp. 1-6.
9. Qi X. et al. Applying neural-network-based machine learning to additive manufacturing: current applications, challenges, and future perspectives // *Engineering*. 2019. vol. 5. no. 4. pp. 721-729.
10. Delazio A. et al. Force jacket: Pneumatically-actuated jacket for embodied haptic experiences // *Proceedings of the 2018 CHI conference on human factors in computing systems*. 2018. pp. 1-12.
11. Andrews C. et al. Extended reality in medical practice // *Current treatment options in cardiovascular medicine*. 2019. vol. 21. no. 4. pp. 1-12.
12. Obukhov A. et al. Methodology for the Development of Adaptive Training Systems Based on Neural Network Methods // *Proceedings of the Computational Methods in Systems and Software*. Springer, Cham. 2021. pp. 238-253.
13. Tapia F. et al. From monolithic systems to microservices: A comparative study of performance // *Applied sciences*. 2020. vol. 10. no. 17. p. 5797.

14. Niknejad N. et al. Understanding Service-Oriented Architecture (SOA): A systematic literature review and directions for further investigation // *Information Systems*. 2020. no. 91. p. 101491.
15. Cerny T., Donahoo M.J., Trnka M. Contextual understanding of microservice architecture: current and future directions // *ACM SIGAPP Applied Computing Review*. 2018. vol. 17. no. 4. pp. 29-45.
16. Rushani L. et al. Differences between Service-Oriented Architecture and Microservices Architecture // *International Journal of Natural Sciences: Current and Future Research Trends*. 2022. vol. 13. no. 1. pp. 30-48.
17. Maurya R. et al. Application of Restful APIs in IOT: A Review // *Int. J. Res. Appl. Sci. Eng. Technol.* 2021. vol. 9. pp. 145-151.
18. Taibi D., Lenarduzzi V., Pahl C. Architectural patterns for microservices: a systematic mapping study // *CLOSER 2018: Proceedings of the 8th International Conference on Cloud Computing and Services Science*; Funchal, Madeira, Portugal, 19-21 March 2018. SciTePress. 2018.
19. Li S. et al. Understanding and addressing quality attributes of microservices architecture: A Systematic literature review // *Information and software technology*. 2021. vol. 131. pp. 106449.
20. Cerny T. et al. On code analysis opportunities and challenges for enterprise systems and microservices // *IEEE Access*. 2020. vol. 8. pp. 159449-159470.
21. Velepucha V., Flores P. Monoliths to microservices-Migration Problems and Challenges: A SMS // *2021 Second International Conference on Information Systems and Software Technologies (ICI2ST)*. IEEE. 2021. pp. 135-142.
22. Городничев М.Г., Полонский Р.В. Оценка возможности использования микросервисной архитектуры при разработке пользовательских интерфейсов клиент-серверного программного обеспечения // *Экономика и качество систем связи*. 2020. № 3 (17). С. 33-43.
23. Bogner J. et al. Microservices in industry: insights into technologies, characteristics, and software quality // *2019 IEEE international conference on software architecture companion (ICSA-C)*. – IEEE, 2019. pp. 187-195.
24. Auer F. et al. From monolithic systems to Microservices: An assessment framework // *Information and Software Technology*. 2021. vol. 137. pp. 106600.
25. Huang L., Zhang C., Zeng Z. Design of a public services platform for university management based on microservice architecture // *Microsystem Technologies*. 2021. vol. 27. №. 4. pp. 1693-1698.
26. Krasnyanskiy M.N., Obukhov A.D., Dedov D.L. Control System for an Adaptive Running Platform for Moving in Virtual Reality // *Automation and Remote Control*. 2022. Т. 83. №. 3. С. 355-366.
27. Obukhov A. et al. Mobile Simulator Control System for Isolating Breathing Apparatus of Software-Hardware Platform // *International Journal of Interactive Mobile Technologies*. 2020. Т. 14. №. 8. С. 32-42.

Обухов Артем Дмитриевич — д-р техн. наук, руководитель лаборатории, лаборатория медицинских VR тренажерных систем для обучения, диагностики и реабилитации, Тамбовский государственный технический университет. Область научных интересов: адаптивные информационные системы, структурно-параметрический синтез, нейронные сети, машинное обучение. Число научных публикаций — 151. obukhov.art@gmail.com; улица Советская, 106, 392000, Тамбов, Россия; р.т.: 8(915)867-6915.

Волков Андрей Андреевич — младший научный сотрудник, лаборатория медицинских VR тренажерных систем для обучения, диагностики и реабилитации, Тамбовский государственный технический университет. Область научных интересов:

информационные технологии, архитектуры информационных систем, распределенные системы управления. Число научных публикаций — 15. didim@eclabs.ru; улица Советская, 106, 392000, Тамбов, Россия; р.т.: 89537030619.

Назарова Александра Олеговна — техник-программист, лаборатория медицинских VR тренажерных систем для обучения, диагностики и реабилитации, Тамбовский государственный технический университет. Область научных интересов: информационные технологии, разработка программного обеспечения, виртуальная реальность. Число научных публикаций — 11. nazarova.al.ol@yandex.ru; улица Советская, 106, 392000, Тамбов, Россия; р.т.: +79204963910.

Поддержка исследований. Работа выполнена при финансовой поддержке Министерства науки и высшего образования РФ в рамках проекта «Разработка медицинских VR тренажерных систем для обучения, диагностики и реабилитации» (№ 122012100103-9).

A. OBUKHOV, A. VOLKOV, A. NAZAROVA
**MICROSERVICE ARCHITECTURE OF VIRTUAL TRAINING
COMPLEXES**

Obukhov A., Volkov A., Nazarova A. Microservice Architecture of Virtual Training Complexes.

Abstract. The task of automating and reducing the complexity of the process of developing virtual training complexes is considered. The analysis of the subject area showed the need to move from a monolithic to a service-oriented version of the architecture. It is found that the use of a monolithic architecture in the implementation of virtual training complexes limits the possibility of modernizing the system, increases its software complexity, and makes it difficult to implement an interface for managing and monitoring the training process. The general concept of the microservice architecture of virtual training complexes is presented, and definitions of the main and secondary components are given. The scientific novelty of the research lies in the transition from the classical monolithic architecture in the subject area of the HTC to the microservice architecture; eliminating the shortcomings of this approach by implementing a single protocol for the exchange of information between modules; separation of network interaction procedures into software libraries to unify and improve the reliability of the system. The use of isolated, loosely coupled microservices allows developers to use the best technologies, platforms and frameworks for their implementation; separate the graphical interface of the simulator instructor from the visualization and virtual reality system; provide the ability to flexibly replace the main components (visualization, interface, interaction with virtual reality) without changing the architecture and affecting other modules. The decomposition of the structural model of the microservice architecture is carried out, and the specifics of the functioning of the main components are presented. The implementation of microservices networking libraries and a JSON-based data exchange protocol is considered. The practical significance of the proposed architecture lies in the possibility of parallelization and reducing the complexity of the development and modernization of training complexes.

Keywords: microservice architecture, microservices, virtual training complexes, intermodule interaction, inter-module interaction, data transfer optimization.

References

1. Zahabi M., Abdul Razak A.M. Adaptive virtual reality-based training: a systematic literature review and framework. *Virtual Reality*. 2020. vol. 24. no. 4. pp. 725-752.
2. Saldana D. et al. Applications of head-mounted displays for virtual reality in adult physical rehabilitation: a scoping review. *The American Journal of Occupational Therapy*. 2020. vol. 74. no. 5. pp. 7405205060p1-7405205060p15.
3. Jerdan S.W. et al. Head-mounted virtual reality and mental health: critical review of current research. *JMIR serious games*. 2018. vol. 6. no. 3. pp. e9226.
4. Zulueta A. et al. Virtual reality-based assessment and rating scales in ADHD diagnosis. *Psicología Educativa. Revista de los Psicólogos de la Educación*. 2019. vol. 25. no. 1. pp. 13-22.
5. Alcañiz M. et al. Eye gaze as a biomarker in the recognition of autism spectrum disorder using virtual reality and machine learning: A proof of concept for diagnosis. *Autism Research*. 2022. vol. 15. no. 1. pp. 131-145.
6. Obukhov A.D. et al. The study of virtual reality influence on the process of professional training of miners. *Virtual Reality*. 2022. pp. 1-25.

7. Drossis G., Birliraki C., Stephanidis C. Interaction with immersive cultural heritage environments using virtual reality technologies. International Conference on Human-Computer Interaction. Springer, Cham. 2018. pp. 177-183.
8. Shinde P.P., Shah S. A review of machine learning and deep learning applications. 2018 Fourth international conference on computing communication control and automation (ICCUBE). IEEE. 2018. pp. 1-6.
9. Qi X. et al. Applying neural-network-based machine learning to additive manufacturing: current applications, challenges, and future perspectives. Engineering. 2019. vol. 5. no. 4. pp. 721-729.
10. Delazio A. et al. Force jacket: Pneumatically-actuated jacket for embodied haptic experiences. Proceedings of the 2018 CHI conference on human factors in computing systems. 2018. pp. 1-12.
11. Andrews C. et al. Extended reality in medical practice. Current treatment options in cardiovascular medicine. 2019. vol. 21. no. 4. pp. 1-12.
12. Obukhov A. et al. Methodology for the Development of Adaptive Training Systems Based on Neural Network Methods. Proceedings of the Computational Methods in Systems and Software. – Springer, Cham. 2021. pp. 238-253.
13. Tapia F. et al. From monolithic systems to microservices: A comparative study of performance. Applied sciences. 2020. vol. 10. no. 17. p. 5797.
14. Niknejad N. et al. Understanding Service-Oriented Architecture (SOA): A systematic literature review and directions for further investigation. Information Systems. 2020. no. 91. p. 101491.
15. Cerny T., Donahoo M.J., Trnka M. Contextual understanding of microservice architecture: current and future directions. ACM SIGAPP Applied Computing Review. 2018. vol. 17. no. 4. pp. 29-45.
16. Rushani L. et al. Differences between Service-Oriented Architecture and Microservices Architecture. International Journal of Natural Sciences: Current and Future Research Trends. 2022. vol. 13. no. 1. pp. 30-48.
17. Maurya R. et al. Application of Restful APIs in IOT: A Review. Int. J. Res. Appl. Sci. Eng. Technol. 2021. vol. 9. pp. 145-151.
18. Taibi D., Lenarduzzi V., Pahl C. Architectural patterns for microservices: a systematic mapping study. CLOSER 2018: Proceedings of the 8th International Conference on Cloud Computing and Services Science; Funchal, Madeira, Portugal, 19-21 March 2018. SciTePress. 2018.
19. Li S. et al. Understanding and addressing quality attributes of microservices architecture: A Systematic literature review. Information and software technology. 2021. vol. 131. pp. 106449.
20. Cerny T. et al. On code analysis opportunities and challenges for enterprise systems and microservices. IEEE Access. 2020. vol. 8. pp. 159449-159470.
21. Velepucha V., Flores P. Monoliths to microservices-Migration Problems and Challenges: A SMS. 2021 Second International Conference on Information Systems and Software Technologies (IC2ST). IEEE. 2021. pp. 135-142.
22. Gorodnichev M.G., Polonskij R.V. Ocenka vozmozhnosti ispol'zovaniya mikroservisnoj arhitektury pri razrabotke pol'zovatel'skikh interfejsov klient-servernogo programmnoho obespecheniya. [Evaluation of the possibility of using micro-service architecture in the development of user interfaces of client-server software]. Economics and Quality of Communication Systems. 2020. vol. 3. no. 17. pp. 33-43. (In Russ.).
23. Bogner J. et al. Microservices in industry: insights into technologies, characteristics, and software quality. 2019 IEEE international conference on software architecture companion (ICSA-C). IEEE. 2019. pp. 187-195.

24. Auer F. et al. From monolithic systems to Microservices: An assessment framework. *Information and Software Technology*. 2021. vol. 137. pp. 106600.
25. Huang L., Zhang C., Zeng Z. Design of a public services platform for university management based on microservice architecture. *Microsystem Technologies*. 2021. vol. 27. №. 4. pp. 1693-1698.
26. Krasnyanskiy M.N., Obukhov A.D., Dedov D.L. Control System for an Adaptive Running Platform for Moving in Virtual Reality. *Automation and Remote Control*. 2022. vol. 83. no. 3. pp.355-366.
27. Obukhov A. et al. Mobile Simulator Control System for Isolating Breathing Apparatus of Software-Hardware Platform. *International Journal of Interactive Mobile Technologies*. 2020. vol. 14, no. 8. pp. 32-42.

Obukhov Artem — Ph.D., Dr.Sci., Head of the laboratory, Laboratory of medical VR simulator systems for training, diagnostics and rehabilitation, Tambov State Technical University. Research interests: adaptive information systems, structural-parametric synthesis, neural networks, machine learning. The number of publications — 151. obuhov.art@gmail.com; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: 8(915)867-6915.

Volkov Andrey — Junior researcher, Laboratory of medical VR simulator systems for training, diagnostics and rehabilitation, Tambov State Technical University. Research interests: information technologies, information system architectures, distributed control systems. The number of publications — 15. didim@eclabs.ru; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: 89537030619.

Nazarova Alexandra — Programmer technician, Laboratory of medical VR simulator systems for training, diagnostics and rehabilitation, Tambov State Technical University. Research interests: information technologies, software development, virtual reality. The number of publications — 11. nazarova.al.ol@yandex.ru; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: +79204963910.

Acknowledgements. Acknowledgements. The work was carried out with the financial support of the Ministry of Science and Higher Education of the Russian Federation within the framework of the project «Development of medical VR simulator systems for training, diagnosis and rehabilitation» (No. 122012100103-9).

Е.С. БАСАН, О.Ю. ПЕСКОВА, О.И. СИЛИН, А.С. БАСАН, Е.С. АБРАМОВ
**ГЕНЕРАЦИЯ ДАННЫХ ДЛЯ МОДЕЛИРОВАНИЯ АТАК НА
БПЛА С ЦЕЛЬЮ ТЕСТИРОВАНИЯ СИСТЕМ ОБНАРУЖЕНИЯ
ВТОРЖЕНИЙ**

Басан Е.С., Пескова О.Ю., Силин О.И., Басан А.С., Абрамов Е.С. Генерация данных для моделирования атак на БПЛА с целью тестирования систем обнаружения вторжений.

Аннотация. На сегодняшний день вопросы, связанные с обеспечением безопасности БПЛА, весьма актуальны. Исследователям необходимо разрабатывать новые методы защиты для своевременного обнаружения атаки и реализации мер по смягчению ее последствий. В работе авторы предлагают новую концепцию обнаружения атак «изнутри» БПЛА. Идея состоит в анализе киберфизических параметров БПЛА, которые могут указывать на атаку и ее возможные последствия. Было определено, что для обнаружения атаки и определения последствий, к которым она может привести, необходимо контролировать не только исходные параметры, но и внутренние киберфизические параметры БПЛА. Это позволит спрогнозировать возможные последствия нападения и принять экстренные меры. Проработана схема влияния атаки на БПЛА и взаимосвязь с инцидентами безопасности, построенная с использованием онтологического подхода. Рассмотрены две основные сущности БПЛА - физические и цифровые аспекты БПЛА. Также показаны примеры цепочек атак, приводящие к различным последствиям. В обзорной части выполнен анализ методов и алгоритмов обнаружения спуфинговых атак с использованием генераторов данных, на основании которого сделаны выводы об их достоинствах и недостатках. Далее, на основании проведенных экспериментов, авторы предлагают метод оценки качества данных и метод генерации аномальных наборов данных, похожих на реальные данные об атаках, которые могут применяться для разработки и тестирования методов обнаружения и блокирования атак. Описана архитектура экспериментального стенда, который был использован в рамках натурного моделирования. На данном стенде, предназначенном для разбора атак с подменой GPS (GPS-спуфинг), проходила отработка нескольких сценариев нормального полета, а затем нескольких сценариев атаки. По результатам проведенных экспериментов был предложен метод, позволяющий имитировать данные, соответствующие атаке, с требуемой точностью. Также был предложен метод оценки качества сгенерированных данных.

Ключевые слова: анализ данных, статистика, атаки, риски, БПЛА.

1. Введение. Атаки на БПЛА и их последствия. Успешно проведенная активная атака на БПЛА может привести к негативным и даже катастрофическим последствиям. При этом важно установить связи между атакой, последствиями атаки и признаками атаки. Установление взаимосвязи между последствиями атак и непосредственно атаками может помочь получить признаки атаки, определить изменения, которые становятся предпосылками атаки, и выделить изменения, приводящие к ее успешному осуществлению [1]. Зачастую атака может быть осуществлена, но с недостаточной степенью интенсивности, благодаря чему не приведет к негативным

последствиям для кибер-физической системы, к которой можно отнести БПЛА.

Если рассматривать БПЛА как кибер-физическую систему, то последствия атак могут быть направлены как на физическую (или аппаратную) базу, так и на цифровую (кибернетическую) компоненту, то есть непосредственно на данные, информацию. Исследования по классификации типов атак и их последствий для БПЛА ведутся давно. Например, в публикациях авторов [2] выделяют пять основных типов атак: Прослушивание (Eavesdropping), Зашумление (Jamming), Внедрение сообщений (Message injection), Удаление сообщений (Message deletion), Модификация сообщений (Message modification). Эти атаки могут затрагивать как цифровые, так и физические компоненты БПЛА.

Рассмотрим рисунок 1, на котором показаны связи между атаками, физической и кибернетической частями БПЛА, а также последствиями атак. Разумеется, на этом рисунке представлены не все наборы возможных последствий атак, а только их общая структура [3]. Тем не менее, эта схема ясно показывает, что практически любая атака, реализованная должным образом, может привести к катастрофическим последствиям не только для самого БПЛА, но и для человека и окружающей среды [4].

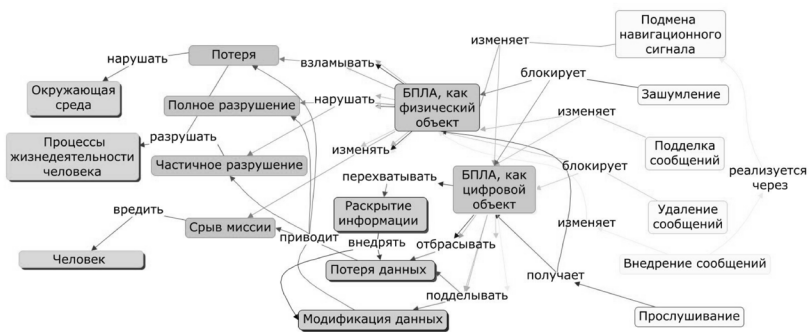


Рис. 1. Схема влияния атаки на БПЛА и взаимосвязь с инцидентами безопасности

Схема, представленная на рисунке 1, построена с применением онтологического подхода. В центре рисунка представлены две основные сущности БПЛА – физические и цифровые аспекты БПЛА. Эти две сущности представляют собой основные концепты онтологии, они представлены серым квадратом, и на них влияют различные атаки.

К цифровым аспектам БПЛА («БПЛА как цифровой объект») можно отнести информацию и данные, которые использует БПЛА в своей работе. Они могут храниться в виде файлов в памяти БПЛА, данных в оперативной памяти, а также передаваться по сети с помощью сетевых протоколов, каналов передачи данных.

К физическому аспекту БПЛА («БПЛА как физический объект») относится аппаратное обеспечение и конструкция БПЛА в целом, включая модули навигации и связи, платы управления, полетный контроллер.

Справа от основных аспектов БПЛА перечислены основные типы атак, которые могут проводиться на БПЛА (от подмены навигационного сигнала до прослушивания). Атаки обозначены светло-серыми прямоугольниками, как другие концепты онтологии. В целом, каждый концепт онтологии отличается друг от друга и представлен разным форматом. Между концептами существуют связи. Связи между концептами описываются действиями. Стрелки и действия связывают между собой концепты. Стрелки на рисунке отличаются, так как они должны позволить определить то, какая атака приводит к какому последствию, чтобы в дальнейшем оценить риски.

Последствия обозначены темно-серыми прямоугольниками, так как эти концепты отличаются от остальных. Это те последствия, которые связаны с физическим воздействием на БПЛА. Светло-серыми прямоугольниками обозначены те последствия, которые связаны с цифровым миром. При этом, как видно из схемы, последствия в самом деле пересекаются и одни последствия могут быть вызваны другими.

В целом, несмотря на то, что на рисунке приведено шесть различных типов атак, их можно объединить в два типа: атаки на нарушение доступности и атаки на получение доступа. К атакам на нарушение доступности относятся Зашумление, Удаление сообщений. Они напрямую могут заблокировать канал связи для БПЛА. При этом косвенно и другие атаки могут с физической точки зрения влиять на БПЛА. К примеру, атаки «Подделка сообщений», «Внедрение сообщений», относящиеся к типу атак на получение доступа, могут привести к тому, что БПЛА будет управляться не легитимным оператором, а злоумышленником. В результате перехвата управления злоумышленником БПЛА может упасть и разбиться, из-за чего станет недоступным.

Как видно из рисунка, по факту разные атаки в итоге могут привести к одним и тем же последствиям. Это связано с тем, что исполнение атаки может отличаться, и в зависимости от цели и

возможностей нарушителя последствия могут варьироваться от изменения направления полета БПЛА до его полного разрушения.

Среди приведенных выше атак выделена атака «Подмена навигационного сигнала». Эта атака выделена отдельно, потому что для ее реализации не нужно производить дополнительных разведывательных действий. Нужно обладать только специальным оборудованием для генерации поддельного сигнала. В случае с GPS сигналом, который распространяется свободно, нужно только иметь мощную антенну и правильно подделать координаты в зависимости от местоположения БПЛА. При этом последствиями для БПЛА от данной атаки могут быть, как угон, так и падение.

Приведем простой пример цепочки атак, которые приводят к одному возможному варианту последствий. Сценарий, представленный на рисунке 2, может включать в себя следующие примеры использования БПЛА: разведывательные операции группой БПЛА, поиск пострадавших, а также детектирование чрезвычайных ситуаций группой БПЛА, ретрансляция связи с помощью БПЛА, мониторинг полей, опрыскивание пестицидами группой БПЛА.

На рисунке 2 показаны три типовые точки входа в систему, которые связаны с подключением к доступному сервису и созданию поддельных пакетов с целью обрыва текущего соединения. Далее, у злоумышленника открывается широкий спектр возможностей, которые он может осуществить для нарушения технологического процесса функционирования БПЛА. Сценариев атак может быть большое количество, но, по сути, они сводятся к трем типам последствий. Это полное нарушение функционирования и крах БПЛА, получение БПЛА в пользование злоумышленника и использование захваченного БПЛА для атак на другие объекты.

Если говорить про инструментарий для проведения атак, то в основном злоумышленником используются программные средства, которые находятся в открытом доступе. Кроме того, в сети интернет имеется большое количество готовых программ и скриптов, которые позволяют автоматизировать процесс перехвата БПЛА. Если говорить об аппаратном обеспечении, то основной упор делается на антенны беспроводной связи, которые должны поддерживать необходимые частоты и каналы связи, на которых работает БПЛА, а также иметь достаточную мощность для реализации атаки. Если же для проведения атаки мощности антенны недостаточно, то можно установить все необходимое оборудование на БПЛА и использовать его как инструмент для атаки.

В качестве недостатка, или уязвимости, который позволяет реализовать злоумышленнику атаку на БПЛА, показана физическая незащищенность каналов связи и самого БПЛА. Это наиболее простой способ проникновения в систему и реализации атак, и именно его практически невозможно устранить из-за «природы» БПЛА и открытости беспроводных каналов связи.




Рис. 2. Пример цепочки атаки с разными точками входа

После определения уязвимости, которую можно проэксплуатировать, злоумышленнику необходимо сформировать вектор атаки и найти точку входа в систему. Вектор атаки формируется на основе обнаружения открытых портов БПЛА. Так как для БПЛА используются программы управления на основе клиент-серверной архитектуры, то, помимо сетевого адреса, у БПЛА должен быть еще и открытый TCP/UDP порт (в зависимости от типов передаваемых данных). Сканирование портов возможно, когда злоумышленник уже находится в сети. В данном случае происходит анализ каналов связи, то есть тех радиочастот, на которых БПЛА может передавать данные. При обнаружении активности на радиочастоте можно сделать вывод о том, что в канале передаются данные. Далее в зависимости от того, на какой радиочастоте осуществляется передача данных, можно предположить, какой протокол связи используется для передачи. В зависимости от протокола связи определяется и точка входа в систему. Далее

непосредственно сам сценарий атаки развивается относительно того, какие именно цели преследует злоумышленник. Он может либо перехватить управление для угона БПЛА путем подделки управляющих команд, либо очистить файлы конфигурации БПЛА для полной его дестабилизации, или использовать его в качестве атакующего для воздействия на группу БПЛА.

Прерывание передачи между БПЛА в таких сценариях (Зашумление, Удаление сообщений) может привести к срыву миссии. Например, если координата в группе БПЛА будет нарушена, то они не смогут качественно выполнить свою работу и вернуться в исходную точку. Если же речь идет о ретрансляции связи, то миссия сразу будет сорвана. Такие события могут повлиять на окружающую среду и, в конечном счете, на человека. Например, беспилотники вели мониторинг местности, и один из них зафиксировал возгорание, но в этот момент на него было совершено нападение [5]. Он не смог вовремя сообщить о том, что происходит. Пока БПЛА не долетит до базы, будет потеряно время, и небольшое возгорание может перейти в пожар.

Атака прослушки канала связи является пассивной, и сама по себе не может повредить аппаратуре БПЛА. Но, как видно из сценария, представленного на рисунке 2, ее можно использовать для сбора данных о каналах связи, протоколах связи, что важно для дальнейшей реализации активной атаки.

Из приведенных примеров видно, что если атака приводит к угону БПЛА, его потере или падению, то эти последствия могут быть связаны и с информацией, которую обрабатывал БПЛА, и с самим БПЛА, и с объектом, с которым непосредственно взаимодействовал БПЛА. Также со временем могут возникнуть косвенные последствия [6].

Таким образом, важно как можно раньше обнаружить атаку на БПЛА, чтобы вовремя принять правильный план минимизации рисков и устранить инциденты информационной безопасности. Часто для обнаружения атак используются методы машинного обучения и искусственные нейронные сети.

2. Анализ методов и алгоритмов обнаружения спуфинговых атак с использованием генераторов данных. В статье [7] авторы предлагают новый алгоритм AMDES (Unmanned Aerial Intrusion Detection System with Multifractal Analysis – беспилотная система обнаружения вторжений с мультифрактальным анализом) для обнаружения атак подделки. Этот новый алгоритм основан на принципах вейвлет-мультифрактального анализа (Wavelet Leader

Multifractal Analysis – WLM), а также машинного обучения. Эта система работает путем сбора информации из сети с помощью сетевых сенсоров, работающих как устройства захвата и передачи информации (распределенные или централизованные датчики, в зависимости от топологии сети). Затем, на этапе предварительной обработки, собранные данные обрабатываются, чтобы лучше выявить их особенности. После того, как сигнатуры получены, следующим шагом становится сравнение сигнатур обычного трафика с теми, которые содержат атакующий трафик, а затем наблюдение за закономерностями, возникающими при различной частоте атак. Чтобы продемонстрировать осуществимость такой методологии при отсутствии работающего БПЛА, авторы разработали испытательный стенд на основе предварительно собранных сетевых записей RADAR. В представленном исследовании авторы собирали данные радиочастотного диапазона, фиксируя радиочастотные сигналы. Базовая станция контролирует работу БПЛА и постоянно обменивается данными телеметрии с БПЛА. Эти радиочастотные сигналы были записаны для анализа. Была обработана 31 запись RADAR, что соответствует данным за один месяц. Каждая исходная запись содержала около 800 000 экземпляров. Имитационные атаки проводились путем случайного выбора нескольких самолетов, а затем случайным изменением записанных траекторий от 0 до 10%. При этом авторы никак не показывают, насколько эффективен их метод создания аномальных событий и насколько они в целом сопоставимы с реальной атакой. Ведь и без атаки, во время реального полета БПЛА, особенно в сложных условиях, могут происходить события, заявляющие о его отклонении от курса. Почему обрабатывается только 10% изменений, авторами не обосновывается. Если вернуться к рисунку 1, то можно предположить следующее: атака была проведена, но неясно, насколько сильно она повлияла на БПЛА и к каким потенциальным последствиям могла привести.

В другой статье [8] описывается система обнаружения атак на основе нейронных сетей с использованием сигнатурного анализа. Для получения сигнатуры трафика в трех измерениях авторы измерили функцию масштабирования в зависимости от статистических моментов, которые могут принимать положительные или отрицательные значения, а также в зависимости от временной шкалы трафика. Затем, используя тот же метод WLM на основе симулятора гибридной сети БПЛА, авторы получили необходимые сигнатуры. Для получения экспериментальных данных авторы использовали стенд, где TCP-трафик генерируется пятью источниками, которые генерируют

длинные TCP-потоки к получателю через маршрутизатор с разной пропускной способностью канала. Рассматриваются два типа DDoS-атак: атака Constant Flash-Crowd (CFC) и атака Progressive Flash-Crowd (PFC). Соответствующие им аномалии были сгенерированы с помощью инструмента HPing3. Авторы получили интересные результаты, особенно в отношении набора данных для обучения нейронной сети с целью обнаружения атак. Тем не менее, остается вопрос, насколько атака может повлиять на БПЛА и насколько легко ее реализовать. Кроме того, реализовать его можно только в том случае, если злоумышленник будет находиться внутри сети и проводить предварительные разведывательные действия.

В статье [9] обсуждается новый метод обнаружения атак подделки на БПЛА. Авторы также используют нейронные сети, они тестируют несколько архитектур беспроводных сетей и подтверждают эффективность своего метода, показывающего достаточно быстрое обнаружение и низкое количество ложных срабатываний. Для обнаружения атак используются следующие факторы: номер спутника, измерение доплеровского сдвига, псевдодальность, время приемника, информация о декодированном времени, фазовый сдвиг несущей, коррелятор подсказок, выход позднего коррелятора, выход раннего коррелятора, запрос в фазе, квадратурный запрос, доплеровские измерения контура несущей, отношение сигнал/шум. Аналогично, при обнаружении атаки авторы полагаются только на внешние факторы и анализируют обстановку вокруг БПЛА. Авторы проводили исследование в лабораторных условиях, и до конца не ясно, как окружающая среда повлияет на обнаружение атаки. Достоинством этой работы является то, что авторы рассматривают несколько вариантов атак GPS-спуфинга, что повышает уровень обнаружения атаки. При этом такая архитектура позволяет детектировать только атаки GPS-спуфинга.

В статьях [10, 11] авторы описывают следующую схему для сбора данных как в случае, когда атака не проводится, так и в случае, когда атака проводится. Используются аппаратное обеспечение, которое представляет собой универсальное периферийное устройство с программно определяемым радио (SDR), и программное обеспечение GNSS-SDR с открытым исходным кодом на основе лицензии GNU. При этом эмулируются спутники с определенными параметрами: отношение сигнал/шум, доплеровский сдвиг, число спутников и т.д. Для эмуляции атаки GPS-спуфинга авторы рассматривают три случая: злоумышленник не знает точное местоположение и координаты дрона и случайным образом генерирует сигнал; злоумышленник знает

местоположение БПЛА и осознанно проводит атаку; третий случай подразумевает использование нескольких синхронно работающих антенн. Авторы используют два варианта нормализации данных, которые собраны в результате эксперимента. Первый вариант описан в статье [10] и включает в себя вычисление коэффициента корреляции Спирмена и модификацию нестационарных данных. Во втором исследовании авторы меняют способ нормализации и вычисляют коэффициент по методу корреляции Спирмена после применения минимаксных технологий. В итоге они используют различные методы машинного обучения и выбирают наилучший для детектирования атаки.

Авторы статьи [12] предлагают анализировать журналы полета БПЛА и из них выделять признаки атаки. Причем, в отличие от предыдущих работ, они предлагают разделить признаки по отдельным категориям и для каждой категории использовать отдельную нейросеть для анализа. Авторы делят журнал полетов на несколько наборов данных в формате CSV в зависимости от имеющегося на БПЛА датчика/темы. При этом данные могут опрашиваться с разной частотой, поэтому также необходимо интерполировать определенные значения. В частности, некоторые признаки были сгруппированы только для компонента GPS: широта, долгота, высота, а также данные о скорости и местоположении. Исходя из такой концепции, авторы считают, что разные атаки влияют на разные кластеры признаков. В действительности, зачастую, когда проводится атака, то она может влиять сразу на несколько типов данных. К примеру, если при атаке зашумления БПЛА предпринимает экстренную посадку, как это делает DJI Mavic Air, то его координаты также будут изменены. При этом система обнаружения атак может ложно определить, что проводится две атаки. Авторы считают, что данные датчика GPS принимаются автопилотом с частотой 5 Гц. Когда поддельные сигналы вводятся в среду моделирования, они отправляются с гораздо большей скоростью. Это заставляет автопилот переключаться на более мощный сигнал [13]. После чего оценка положения БПЛА изменится, что приведет к его отклонению от курса [14]. Когда атака прекращается, БПЛА снова фиксируется на законном сигнале и перемещается, чтобы скорректировать свое положение, и возобновляет свою траекторию в миссии. В действительности, когда реализуется атака, то перестроение происходит недостаточно плавно. В реальной среде, когда БПЛА летит в открытом небе и получает сигнал от реальных спутников, злоумышленник, имеющий даже мощную антенну, не может в полной точности смоделировать сигнал спутников. Возникает

дополнительный шум, что доказано в работах авторов, рассмотренных ранее. Кроме того, изменяется число спутников, на которых фиксируется БПЛА, могут измениться не только координаты, но и высота полета [15]. Таким образом, число факторов намного больше, чем предполагают авторы [12]. Авторы статьи [16] используют этот же набор данных, только проводят некоторые преобразования. К примеру, они делают признаки на еще более укрупненные пять категорий. При этом они удаляют лишние признаки согласно двум правилам. По первому правилу удаляются все не универсальные признаки, остаются только те, которые присущи всем БПЛА. Второе правило подразумевает исключение параметров, которые имеют постоянные, неизменные значения, и параметров, которые могут иметь пропущенные значения. Если первое правило действительно позволяет унифицировать набор данных, то по поводу второго правила есть вопросы. К примеру, есть датчики, которые показывают значение true/false – это некое состояние сенсора, которое действительно не должно меняться во время полета, но фиксация его изменения и экстренное реагирование на него могут привести к положительным последствиям. Авторы унифицировали длину каждой функции с помощью пула временных меток, а также использовали упоминаемую ранее минимаксную технологию для приведения данных к единому масштабу. В таблице 1 приведены сравнительные характеристики рассмотренных методов.

Таблица 1. Сравнение методов и алгоритмов обнаружения спуфинговых атак с использованием генераторов данных

Работа	Содержание	Достоинства	Недостатки
[7]	Система обнаружения вторжений на основе мультифрактального анализа и машинного обучения для UAS/RADAR.	Эффективные алгоритмы вейвлет-мультифрактального анализа и машинного обучения. Экспериментальный стенд на основе большого количества собранных реальных данных.	Не показана эффективность метода генерации аномальных событий. Не обоснованы количественные характеристики (берется только 10% изменений). Не показано влияние атаки на БПЛА. Выявляются признаки атаки во внешних по отношению к БПЛА сущностях. Не рассматривается внутреннее состояние БПЛА.
[8]	Система обнаружения вторжений в сеть для оперативной связи БПЛА: от разработки методологии до проверки в реальных испытаниях.	Применяются эффективные алгоритмы вейвлет-мультифрактального анализа и машинного обучения. Для обучения нейросетей были разработаны достаточные наборы данных	Не рассмотрено, насколько легко могут быть реализованы данные атаки, с какими ограничениями можно столкнуться. Авторы не исследуют, как атаки и их признаки напрямую влияют на сам БПЛА и его характеристики. Выявляются признаки атаки во внешних по отношению к БПЛА сущностях.

Работа	Содержание	Достоинства	Недостатки
[9]	Методы динамического отбора для обнаружения атак с подменой GPS на БПЛА.	Протестированы различные архитектуры беспроводных сетей. Достаточно быстрое обнаружение и низкое количество ложных срабатываний. Несколько вариантов атак GPS-спуфинга.	Исследования проводились только в лабораторных условиях. Метод требует дополнительных мощностей. Авторы не исследуют, как атаки и их признаки напрямую влияют на сам БПЛА и его характеристики. Выявляются признаки атаки во внешних по отношению к БПЛА сущностях. Рассматривается только внешнее воздействие на БПЛА, не анализируется его внутреннее состояние.
[10], [11]	Модели контролируемого машинного обучения на основе дерева для обнаружения атак спуфинга GPS на БПЛА	Универсальная схема сбора данных. Широкий набор параметров. Различные методы обработки и нормализации данных, что позволяет выбрать оптимальный для конкретного случая. Набор вариантов проведения атак спуфинга.	Не сформулированы требования и ограничения для эмулируемых данных. Есть ограничения применимости предложенных методов. Выявляются признаки атаки во внешних по отношению к БПЛА сущностях. Рассматривается только внешнее воздействие на БПЛА, не анализируется его внутреннее состояние.
[12]	Новый метод обнаружения сенсорных атак на беспилотные летательные аппараты	Разделение признаков, позволяет не только обнаруживать атаки, но и потенциально классифицировать тип атаки или целевой датчик.	Разметка данных не учитывает пересечения параметров. Атаки формируются только в лабораторных условиях. Число факторов намного больше, чем предполагают авторы. Авторы не исследуют, как атаки и их признаки напрямую влияют на сам БПЛА и его характеристики. Выявляются признаки атаки во внешних по отношению к БПЛА сущностях. Рассматривается только внешнее воздействие на БПЛА, не анализируется его внутреннее состояние.
[16]	Неконтролируемая система обнаружения вторжений для беспилотных летательных аппаратов с меньшими усилиями по маркировке.	Авторы используют методы нормализации сырых данных. Авторы унифицировали длину каждой функции с помощью пула временных меток, а также использовали минимаксную технологию для приведения данных к единому масштабу.	Разметка данных не учитывает анализ данных от критически важных сенсоров. Авторы не исследуют, как атаки и их признаки напрямую влияют на сам БПЛА и его характеристики. Выявляются признаки атаки во внешних по отношению к БПЛА сущностях. Рассматривается только внешнее воздействие на БПЛА, не анализируется его внутреннее состояние.

Подводя итог рассмотренным исследованиям по теме обнаружения атак на БПЛА, можно резюмировать следующее.

Авторы предлагают оригинальные методы формирования и нормализации наборов данных, которые можно применять не только к

изучаемым авторами наборам данных, но и к другим данным. Практически везде используются разные архитектуры нейросетей, авторы декларируют высокую эффективность методов обнаружения атак. Во всех исследованиях выявляются признаки атаки во внешних по отношению к БПЛА сущностях, то есть в целом анализируются сетевой трафик или шум полосы пропускания, уровень шума в радио среде. Несомненно, рассмотренные факторы идентифицируют атаку и являются ее признаками, но нельзя однозначно определить, насколько эффективно атака может повлиять на сам БПЛА и к каким последствиям она может привести. Предлагаемые методы предполагают наличие третьей стороны, собирающей информацию и обнаруживающей атаку. Не всегда возможно проанализировать радиочастотный диапазон вблизи БПЛА, часто аппарат находится далеко. Если же сам БПЛА вынужден постоянно анализировать радиочастотный диапазон или активность сети, то это может повлиять на его производительность.

Таким образом, важной задачей становится сбор и обработка информации, связанной с БПЛА, и наше исследование направлено на разработку метода подготовки набора данных для разработки и тестирования систем обнаружения вторжений для БПЛА.

3. Архитектура экспериментального стенда. Открытый характер структуры сигнала GPS делает его уязвимым для атак с подменой GPS, которые могут осуществляться открыто или скрытно. В первом случае мощный сигнал, создаваемый злоумышленником, подавляет сигнал, поступающий со спутников. Эту атаку легко осуществить, но она требует значительных ресурсов [17]. При реализации скрытой атаки мощность сигнала постепенно увеличивается до тех пор, пока целевая система полностью не переключится на поддельный сигнал, транслируемый злоумышленником. Этот подход более сложен и требует большего количества компонентов и детальной подготовки, но потребляет меньше энергии и обеспечивает плавный переход целевой системы на поддельную. Если БПЛА полностью автономен, то бортовая система выведет БПЛА на ложное местоположение цели или наземную станцию. Этот тип атаки приведет к провалу миссии и возможной потере БПЛА. Если позиция атакуемого БПЛА выбрана недостаточно точно, система безопасности БПЛА может обнаружить атаку, после чего БПЛА может перейти на ручное управление или изменить траекторию по заданному сценарию поведения [18]. Неточное время также может привести к обнаружению атаки или сбою внутренней

синхронизации системы. Все эти факторы необходимо учитывать на подготовительном этапе атаки [19].

Проведение атаки возможно только в том случае, если система управления БПЛА переведена в автоматический режим и полностью полагается на систему навигации, использующую датчики GPS/ГЛОНАСС. Для получения экспериментальных данных для данного исследования и моделирования поведения БПЛА в штатных условиях и при атаке был выбран метод натурного моделирования. В ходе исследования разработан экспериментальный БПЛА, в основе которого были полетный контроллер PixHawk 4 и плата управления Raspberry PI 4. Состав стенда показан на рисунке 3. Для управления полетом БПЛА использовался планировщик QGroundControl, который обеспечивает полное управление полетом и планирование задач для любого БПЛА с поддержкой протокола MAVLink. По результатам миссии были сформированы два типа журналов, которые в дальнейшем были проанализированы: Dataflash и telemetry. Для проведения атаки использовался специализированный радиочастотный модуль HackRF One.

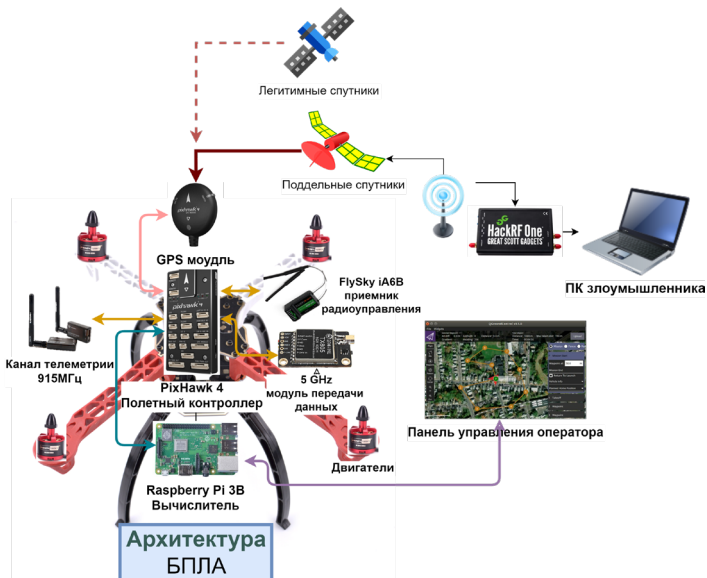


Рис. 3. Архитектура натурной модели БПЛА для проведения экспериментального исследования

С помощью данного стенда проходила отработка нескольких сценариев нормального полета, а затем нескольких сценариев атаки. Всего было выполнено до 20 тестовых испытаний. В результате испытаний были собраны экспериментальные данные для анализа из журналов логирования.

4. Экспериментальное исследование. Экспериментальное исследование проходило с применением метода натурального моделирования. Испытания проводились на полигоне в безветренную погоду при хорошей видимости. Экспериментальный БПЛА подвергался атаке подделки GPS сигнала. Атака осуществлялась путем направления сигнала большей GPS мощности с целью имитации спутников. Для реализации атаки использовалось устройство HackRF One. Для более корректной реализации атаки скачивался ежедневный файл эфемерид GPS, который находится на сайте НАСА (Национальное управление по аэронавтике и исследованию космического пространства). Далее необходимо сформировать файл с координатами для передатчика. После чего можно транслировать координаты через HackRF. В ходе испытаний с атакой БПЛА не подвергался атаке в течение 3–5 минут, а затем атака осуществлялась в течение 10 минут. В ходе атаки злоумышленник установил фиктивное местоположение БПЛА. Следовательно, наблюдалось изменение высоты БПЛА, а также смещение БПЛА в заданную атакующим точку. В нескольких экспериментах при резком прерывании атаки наблюдалось падение БПЛА.

В данной статье рассматриваются атаки, связанные с воздействием на GPS-сигнал, который позволяет БПЛА ориентироваться на местности. Большинство исследователей также анализируют GPS-сигналы, либо передачу данных по радиочастотным каналам. Анализ GPS-сигнала обусловлен тем, что большинство систем навигации для БПЛА построены на основе данного типа сигнала. Используемые в исследовании БПЛА могут позиционироваться с использованием как GLONASS, так и GPS систем. Тем не менее, позиционирование с помощью одной GLONASS системы является затруднительным, так как число спутников, которые фиксирует БПЛА (обычно 4 – 6) недостаточно для корректной работы. Число спутников BEIDOU в той местности, где испытывался БПЛА, также незначительное. Для корректной работы БПЛА требуется от 11 спутников, на данный момент такое количество может быть обеспечено только навигационной системой GPS.

В статье [20] подробно описан реализованный сценарий атаки на БПЛА, сам же экспериментальный стенд подробно описан в статье [21].

В целом план эксперимента состоял из следующих этапов:

1. БПЛА завис в воздухе над одной точкой на три минуты.
2. БПЛА был поднят в воздух и завис над точкой в течение минуты.

2.1. БПЛА был атакован. Злоумышленник попытался отвести БПЛА в сторону.

2.2. После того, как БПЛА начал движение и прошел 3–6 метров, атака закончилась.

3. После завершения атаки было два варианта развития событий.

3.1. БПЛА пытался вернуться в исходную точку.

3.2. БПЛА упал на землю.

Порядок проведения атаки:

Для передачи положения в определенной точке необходимо:

1) Сформировать файл с координатами для передатчика с помощью команды:

```
./gps-sdr-sim -b 8 -e brdc1900.20n -l 47.204715, 38.940236 -o Location.bin,
```

– где: brdc1900.20n – ежедневный файл эфемерид GPS, который находится на сайте НАСА;

– 47.204715, 38.940236 – широта и долгота;

– Location.bin – имя файла на выходе.

2) Транслировать координаты через HackRF командой:


```
hackrf_transfer -f 1575420000 -s 2600000 -a 1 -x 15 -R -t Location.bin,
```

– где: f – частота вещания GPS спутников;


– x – мощность сигнала (максимум 47);

– R – повторение.


Проанализируем данные, полученные экспериментально. Результаты анализа показаны на рисунке 4. Графики получены путем реализации атаки на экспериментальный БПЛА согласно описанному сценарию. Атака заключалась в том, что с помощью передатчика и направленной антенной производилась трансляция поддельного местоположения БПЛА. Для трансляции местоположения использовалась частота, на которой работает протокол GPS. Передавалась геопозиция, в которой должен находиться БПЛА, которая включает в себя широту, долготу и высоту полета. На рисунке 4 приведены примеры изменений некоторых параметров под воздействием атаки на протяжении трех разных экспериментов и в нормальном состоянии.




а)




б)




в)




г)



д)



е)



и)

Рис. 4. Изменение киберфизических параметров БПЛА под воздействием атаки: а) Оценка абсолютной высоты полета по GPS – Absolute Altitude GPS Estimate; б) Количество используемых спутников – Num Satellite Used; в) Уровень шума GPS – GPS Noise; г) Широта полета – Latitude; д) Долгота полета – Longitude; е) Напряжение аккумуляторной батареи – Battery voltage; и) Скорость – Velocity, м/с (заданные значения X, Y, Z)

При проведении экспериментального исследования фиксировался момент начала атаки, то есть время, когда HackRF начинает транслировать поддельный сигнал. Время на полетном контроллере синхронизировано со временем на пульте оператора, который запускает атаку. Поэтому имеется возможность проанализировать файлы журнала полета, сопоставив временные метки. Время начала атаки при каждом из трех экспериментов сопровождается изменением числа спутников, которые фиксирует БПЛА, а также увеличением значения сигнал/шум. Остальные параметры могут начать изменяться немного позже. Из рисунка 4 (а) видно, что абсолютная высота полета стала отрицательной в первом эксперименте, это сопровождалось резким снижением и дальнейшим падением БПЛА. Отрицательная абсолютная высота свидетельствует о том, что БПЛА был полностью дезориентирован (примеры отрицательной абсолютной высоты встречаются на суше реже: впадина Каттара, Африка (-133 м), Северная Америка (-85 м), Приатлантические районы Нидерландов и др.). При проведении эксперимента БПЛА была задана точка вблизи Нидерландов, именно поэтому высота была отрицательной. Кроме того, как видно из рисунков 4 (д), 4 (г), значение широты и долготы также резко менялись в случае первого эксперимента. Это означает, что БПЛА

сразу после начала атаки начал резкое изменение маршрута полета (хотя должен был «зависать» над одной точкой, установленной оператором). При этом во время эксперимента наблюдалась резкая смена местоположения БПЛА с его дальнейшим падением. Это резкое изменение также вызвало увеличение скорости, как видно из рисунка 4 (и). Для остальных двух случаев атаки транслировалась точка, которая находилась на полигоне, поэтому таких значительных перепадов не наблюдалось. Из рисунка 4 (б) видно, что при реализации эксперимента 1, 3 GPS-приемник теряет связь с реальными спутниками и через некоторое время переключается на фальшивые. Это сопровождается тем, что число спутников в какой-то момент снижается до нуля. Для эксперимента 2 переход осуществляется более плавно без нулевых значений. Эксперимент 2 сильнее всего повлиял на перемещение БПЛА, также это отразилось на энергопотреблении, которое резко увеличилось, как видно из рисунка 4 (е) для эксперимента 2.

График «шум_норм» на рисунке 4 показывает изменение параметров при отсутствии воздействия со стороны атаки на БПЛА. Таким образом, как видно из рисунков, когда БПЛА должен зависать на месте при удержании высоты, то его показатели либо не должны меняться, либо могут незначительно смещаться.

Из рисунка 4 видно, что для всех трех экспериментов наблюдалось резкое изменение всех параметров. При нормальном состоянии изменения параметров могут наблюдаться, но это отклонение намного ниже. Исходя из этого, оценить и описать ситуацию, при которой возникает атака, можно с помощью среднеквадратического отклонения и среднего значения для каждого параметра. Регулируя данные метрики (среднее значение и среднеквадратическое отклонение), можно добиться конструирования графиков, которые отражают условия проведения атаки без прибегания к реализации реальной атаки. Кроме того, выявленные зависимости позволяют изменять данные нормального полета в режиме реального времени для симуляции атаки.

Полетный контроллер Pixhawk 4 позволяет собирать большое число параметров от встроенных сенсорных систем. Тем не менее, не все из них являются достаточно информативными для обнаружения атаки Подделка GPS сигнала. Данная атака, как было выявлено из экспериментального исследования и теоретического анализа литературы, направлена на «угон» БПЛА, а побочным следствием атаки может стать его падение.

В связи с этим, в данном исследовании предлагается моделирование следующих наборов параметров:

- Загруженность центрального процессорного устройства (ЦПУ). В данном случае речь идет о процессоре полетного контроллера БПЛА.

- Высота полета БПЛА (h_a). Имеется в виду высота относительно земли, которая фиксируется внутренними датчиками БПЛА. Высота задается при формировании полетного задания или оператором с помощью пульта управления.

- Число спутников (G_n). БПЛА при полете фиксирует число спутников, от которых он получает сигнал в данный момент, для корректной работы данное число должно превышать 10.

- Уровень шума (G_{noi}). Данный показатель фиксируется радио модулем, который получает сигнал, и при значении, превышающем 150, можно говорить об атаке.

- Координаты БПЛА (x, y, z). Координаты, которые фиксируются сенсорной системой БПЛА при позиционировании на местности.

- Скорость полета (S). Измеряется в м/с и задается оператором.

- Ускорение (V). Фиксируется для двигателей, как правило, фиксируется по осям x, y, z .

- Широта (Lat). Координаты БПЛА, получаемые от глобальной навигационной системы. Задаются оператором.

- Долгота (Lon). Координаты БПЛА, получаемые от глобальной навигационной системы. Задаются оператором.

5. Обзор наборов данных для получения и тестирования систем обнаружения атак, а также методов их формирования. Во многом эффективность систем обнаружения атак зависит от наборов данных, используемых для их обучения и тестирования, и исследователи по-разному подходят к вопросу формирования таких датасетов. Однако получение наборов данных хорошего качества для обучения и тестирования IDS является сложной задачей.

Большинство исследователей оценивают производительность систем IDS, используя так называемые эталонные наборы данных.

В 1998 году Лаборатория Линкольна Массачусетского технологического института создала первый набор данных для обнаружения вторжений, названный DARPA, в рамках исследования, финансируемого DARPA [22]. В 1999 году исследователи Калифорнийского университета обновили и проанализировали файлы

tcpdump DARPA, в результате чего был создан набор данных KDD CUP 99 [23–24].

В [25] авторы подробно рассматривают несколько таких классических наборов данных. Рассматривались DARPA / KDD CUP 99, NSL KDD CUP 99, CAIDA, CICDS 2017, ADFA-LD & ADFA-WD, KYOTO. Набор данных KDD Cup '99 широко используется в исследованиях IDS и разработке новых стратегий защиты компьютерных сетей от различных угроз. Сложность исследования, влияние дублированных и избыточных записей, а также неравное количество участников исследования – все это проблемы, которые могут поставить его под угрозу.

Авторы [26] также провели исследование широко используемых наборов данных IDS для исследования алгоритмов машинного обучения в области IDS и реализованных атак. Их исследование показывает, что до 60% работ используют набор данных NSL-KDD, до 30% используют набор данных STU-13 и до 10% используют набор данных CIC-IDS2017.

В [27] авторы оценили производительность моделей IDS, обучая их с помощью наборов данных NSL-KDD и CIC-IDS2017 по отдельности. Они использовали состязательные методы: DeepFool, JSMA, FGSM и CW. Исследование проводилось только на основе атак типа «отказ в обслуживании» (DoS). Результаты оценки показывают, что общая производительность модели при обучении с использованием набора данных CIC-IDS2017 снизилась на 40 % и на 13 % при обучении с помощью NSL-KDD [28].

В [29] рассматриваются наборы данных для обучения IDS в привязке к атакам на системы интернета вещей (IoT). Специфика системы определяет и способы формирования наборов данных, которые чаще всего комплектуются из реальных данных, не обязательно содержащих данные об атаках (например, данные из системы диспетчерского управления и сбора данных SCADA). Но здесь также часто используются стандартные наборы данных, например, были приведены примеры использования наборов данных AWID, NSL-KDD. Подробно были рассмотрены CIC-IDS2017, UNSW-NB15, DS2OS, BoT-IoT, KDD Cup 1999, NSL-KDD. Были сделаны выводы о том, что в большинстве исследований использовались KDD99, NSL-KDD и реальные частные наборы данных. NSL-KDD широко используется исследователями с различными методами машинного обучения. Этот набор данных дал лучшую точность. Он широко использовался для атак Probing, U2R, DoS и R2L. KDD99 имеет те же функции, что и NSL-KDD, который включает 41 функцию

и 1 атрибут класса, который подпадает под 4 типа атак: зондирующие атаки, U2R-атаки, R2L-атаки и DoS-атаки. NSL-KDD используется чаще по сравнению с KDD99, но результаты последнего лучше, чем у других общедоступных наборов данных. Ученые показали, что включение общедоступных наборов данных, таких как NSLKDD, UNSW-NB15 и KDDCUP99, в модели обнаружения угроз IoT представляет собой серьезную проблему. Когда модели атак IoT сочетаются с общедоступными наборами данных с проблемами качества, результаты могут быть ниже среднего [30].

В самом деле, в последнее время стало доступно значительное количество наборов данных, которые охватывают относительно модернизированные сценарии сетевого трафика [31]. Кроме того, появились методики модификации существующих наборов данных. Так, в [32] для разработки и проверки контролируемых моделей машинного обучения в системах обнаружения атак также использовался набор данных NSL-KDD, записи в котором были тщательно отобраны – он состоит в общей сложности из 43 элементов, из которых 41 элемент представляет собой входящий трафик, а 2 атрибута состоят из меток и оценок [33, 34]. В представленном проекте был использован встроенный метод (дополнительный древовидный классификатор) для выбора функций, который сочетает в себе качества методов фильтрации и обертки и предоставляет функции в зависимости от их важности.

В работе [35] авторы также говорят о том, что одной из проблем в области систем обнаружения атак является то, что большая часть исследовательской работы проводилась с использованием старых наборов данных. В отличие от области изображений данные в области IDS быстро устаревают, поскольку шаблоны данных в сетях быстро меняются, а поведение атак становится изоциренным. Набор данных должен отражать современное поведение сети и охватывать достаточные сценарии атак, чтобы модель IDS изучала широкий спектр характеристик трафика. Современные наборы данных включают в себя современное поведение сети и сценарии атак. Чем реалистичнее набор данных, тем эффективнее он может создать модель IDS в реальной среде. Авторы исследования анализируют наборы данных UNSW-NB15, Bot-IoT и CSE-CIC-IDS2018 и обсуждают, как работают различные алгоритмы классификации, когда модель IDS обучается с каждым из выбранных наборов данных.

Во всех рассмотренных работах говорится о том, что использование стандартных наборов данных не является достаточно

эффективным, поэтому разработка собственных алгоритмов генерации реалистичных наборов данных актуальна.

6. Метод моделирования данных. Особенностью разрабатываемого метода является то, что он позволяет выявить характеристики в изменении киберфизических параметров БПЛА на основе анализа последствий реальных атак и смоделировать данные характеристики, схожие с реальными данными, но при этом отличающиеся от реальных. Как было сказано ранее, проблемой многих работ является отрыв от связи с реальными сценариями атак и реальными киберфизическими системами. Изучив особенности изменения киберфизических параметров под воздействием атак, можно генерировать поддельные данные с целью тестирования атак в режиме реального времени. Кроме того, большинство методов моделирования наборов данных и генерации данных основаны на том, что некоторый внешний монитор следит за трафиком и активностью системы. При этом если речь идет о БПЛА, то он не всегда находится в пределах видимости базовой станции и может действовать автономно. Предлагаемый метод моделирования данных направлен на использование в системах обнаружения атак на узле, для случаев, когда узел анализирует изменение собственных параметров. Таким образом, новизной данного метода является возможность моделирования изменений киберфизических параметров БПЛА путем анализа того, как на них реагирует внутренняя система БПЛА, выделяя разные периоды активности, что способствует созданию наборов данных, которые с высокой вероятностью приближены к ситуации реальной атаки. В результате решается проблема актуальности генерируемых данных, их достоверности и реалистичности, а также появляется возможность тестирования систем обнаружения вторжений, которые работают внутри БПЛА и анализируют изменения киберфизических параметров БПЛА в режиме реального времени. Как видно из рисунка 5, при проведении атаки на БПЛА изменение данных не происходит прямолинейно и однозначно. Найти зависимость достаточно сложно, можно лишь попытаться описать структуру полученных данных. Для этого применим критерий χ^2 . Выдвигается нулевая гипотеза о том, что наблюдаемые частоты соответствуют ожидаемым (т.е. между ними нет разницы, так как они взяты из одной и той же генеральной совокупности). Если это так, то разброс будет относительно небольшим, в пределах случайных колебаний. Мера распространения определяется статистикой χ^2 . Далее, либо полученная статистика сравнивается с критическим значением (для соответствующих степеней свободы и уровня значимости), либо, что

корректнее, вычисляется наблюдаемое p -значение, т. е. вероятность получения такого или даже большего значения статистики при справедливости нулевой гипотезы. Например, известно, что высота полета должна быть равна 15, будем считать это нулевой гипотезой и подтвердим эту гипотезу, сравнив ее с текущим значением высоты. Воспользуемся формулой:

$$F\chi^2(A) = \sum_{i=1}^r \sum_{j=1}^c \frac{(A_{ij} - O_{ij})^2}{O_{ij}}, \quad (1)$$

$F\chi^2(A)$ – это статистическая функция, при больших n имеет приблизительно χ^2 – распределение с $(r-1)(c-1)$ степенями свободы, где i – номер строки (от 1 до r), j – номер столбца (от 1 до c). Критерий χ^2 используется, чтобы определить, подтверждается ли гипотеза экспериментом. A_{ij} – фактическое значение параметра в текущий момент времени (то значение параметра, которое получено от полетного контроллера и записано в матрицу значений), интервал данных, который содержит результаты наблюдений, подлежащие сравнению с ожидаемыми значениями. O_{ij} – ожидаемое значение параметра в ячейке ij (то значение, которое было записано в матрицу при нормальном полете), или теоретическое, то которое рассчитано заранее. В данном случае имеется в виду, что сравнивается матрица значений, которые получены при нормальном полете и при текущем полете, сравнение происходит поэлементно.

На рисунке 5 видно, что есть периоды, когда значение падает ниже 0.5, а иногда и достигает единицы. Это связано с наличием изменений показателя высоты. Можно увидеть области, когда значение сильно отличается от заданного.

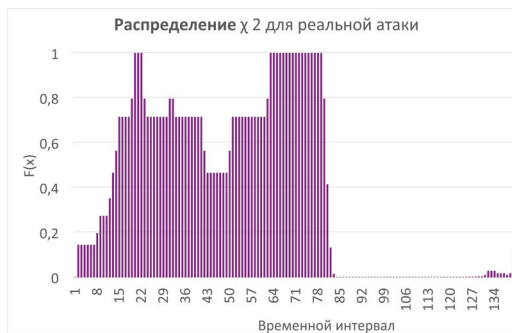


Рис. 5. Распределение χ^2 для индикаторной высоты полета

Прямоугольники характеризуют ситуацию, когда значение близко к заданному. Эта картина позволяет выявить периоды изменений. Далее для каждого из периодов вычисляем стандартное отклонение и среднее значение по формулам:

$$S_o = \sqrt{\frac{\sum (A - \bar{A})^2}{(n-1)}}, \quad (2)$$

$$M(A) = \int_{-\infty}^{\infty} af(a)da. \quad (3)$$

Пусть высота – это непрерывная случайная величина A , заданная плотностью распределения $f(a)$, n – объем выборки, \bar{A} – среднее арифметическое выборки. Вычисляем это значение для каждого из интервальных распределений, определенных с помощью распределения χ^2 . Затем генерируем случайные значения в пределах этих параметров, используя функцию нормального распределения. Функция имеет следующие параметры:

- Вероятность P_{Gauss} . Вероятность, соответствующая нормальному распределению. Вместо значения вероятности генерируем случайное число соотдано формуле 4.

- Среднее \overline{Cph} . Распределение среднего арифметического для киберфизического параметра Cph .

- Стандартное отклонение σ_{Cph} . Стандартное отклонение распределения для киберфизического параметра.

$$F_{gen} = P_{Gauss}(f_{rand}; \overline{Cph}; \sigma_{Cph}), \quad (4)$$

где F_{gen} – функция для генерации значения киберфизического параметра.

В результате получаем следующий набор данных для высоты полета. Полученные данные выглядят не совсем похожими на реальные, что видно из рисунка 6. Реальные данные представлены внизу графика, данные, полученные этим методом, представлены рядом с эмулированными данными 3. Для их улучшения произведем над ними преобразования методом «скользящего среднего».

Воспользуемся формулой:

$$WA_t = \frac{\sum_{i=1}^{n-1} W_{t-i} \times a_{t-i}}{\sum_{i=1}^{n-1} W_{t-i}}, \quad (5)$$

где WA_t – значение взвешенного скользящего среднего в точке, n – количество значений исходной функции для расчета скользящего среднего, W_{t-i} – вес (весовой коэффициент), a_{t-i} – значение исходной функции в момент времени, удаленное от текущего на интервалы.





Рис. 6. Результат эмуляции данных для высоты полета


Три верхних графика были обучены с использованием метода скользящего среднего. Для улучшения метода попробуем вычислить среднее значение и стандартное отклонение не для всего интервала, а разбить его на еще меньшие интервалы, для которых значение χ^2 максимально похоже. Результаты показаны на рисунке 7.



а)



б)



в)

Рис. 7. Результат эмуляции данных: а) высоты полета; б) ускорения БПЛА; в) числа спутников, которые зафиксировал БПЛА

Визуально данные выглядят лучше. Необходимо подтвердить, что полученные данные коррелируют с исходными данными атаки.

Для этого воспользуемся коэффициентом корреляции Пирсона (r), который рассчитывается по следующей формуле:

$$r = \frac{\sum (a_{real} - \bar{a}_{real})(a_{emul} - \bar{a}_{emul})}{\sum (a_{real} - \bar{a}_{real})^2 \sum (a_{emul} - \bar{a}_{emul})^2}. \quad (6)$$

Результаты представлены в виде гистограммы на рисунке 8. На рисунке 8 (а) видно, что данные, полученные вторым методом, имеют более высокий коэффициент Пирсона, а значит, они в большей

степени коррелируют с исходными. На рисунке 8 (б) представлены расчеты коэффициента Пирсона для ускорения и числа спутников, полученные вторым методом. В зависимости от целей, можно добиться того, чтобы сгенерированные данные были менее похожи на оригинал. Таким образом, мы можем изменять любые данные, независимо от их размера и порядка.





Рис. 8. Гистограмма коэффициента корреляции Пирсона: а) для высоты полета б) для числа спутников и ускорения БПЛА

Этот метод, а также оценка качества данных позволит получить столько данных, сколько необходимо для обучения нейронной сети или тестирования метода обнаружения атак. При изменении среднего значения и среднеквадратического отклонения можно модифицировать поддельные данные, при этом форма данных и их правдоподобие не изменятся. На рисунке 9 представлены результаты генерации данных для числа спутников, высоты полета и ускорения.







Рис. 9. Образцы сгенерированных данных для: а) числа спутников; б) высоты полета; в) ускорения

Из рисунка 10 (б) видно, что данные для высоты полета были дополнительно модифицированы и значения высоты были получены для более высоких диапазонов. При этом коэффициент корреляции Пирсона для сгенерированных данных равен 0,98, что говорит о достаточно высоком правдоподобии данных. Коэффициент правдоподобия позволил оценить реалистичность подделываемых данных.

7. Заключение. Признаком атаки, в частности, атаки на подмену навигационного сигнала, как показало экспериментальное и теоретическое исследование, является нестандартное изменение параметра, получаемое от полетного контроллера БПЛА. Под нестандартным изменением можно понимать увеличение/уменьшение математического ожидания параметра и рост среднеквадратического отклонения. Для того чтобы в автоматическом режиме определять такие участки графиков с изменением параметров, которое

характеризуется как нестандартное, необходимо использовать функцию, которая нормализует эти изменения. Каждый из анализируемых параметров имеет свою размерность и границы максимального/минимального значения. Поэтому для того, чтобы выявить признаки изменений, было выбрано распределение χ^2 , которое позволяет определить вероятность соответствия между двумя временными рядами. Имея информацию о нормальном и аномальном полете БПЛА, можно сопоставить временные ряды и вычислить степень отклонения значения во время атаки. На основании распределения χ^2 удастся выделить зоны наибольших и наименьших изменений. Разделив на участки графики с сырыми данными, можно, воспользовавшись обратной функцией нормального распределения, задав среднее значение и среднеквадратическое отклонение, получить набор случайных значений, которые будут похожими на те значения, которые возникают во время атаки. Тем не менее, эти значения генерируются слишком случайным образом и не коррелируют в достаточной степени с реальными, что оценивалось с помощью коэффициента Пирсона. Для улучшения качества генерируемых данных было принято решение использовать метод «скользящего среднего». Благодаря сглаживанию значений удалось повысить степень корреляции и получить высокие значения коэффициента Пирсона. Таким образом, данный механизм позволяет регулировать генерируемые данные на различных участках графика, а с помощью изменения среднеквадратического отклонения и среднего значения можно контролировать степень изменения параметра.

Таким образом, данное исследование позволило добиться следующих результатов.

Во-первых, было определено, что для обнаружения атаки и определения последствий, к которым она может привести, необходимо контролировать не только исходные параметры, но и внутренние кибер-физические параметры БПЛА. Это позволит спрогнозировать возможные последствия нападения и принять экстренные меры.

Во-вторых, был предложен метод имитации данных, соответствующих атаке. Этот метод позволяет имитировать данные с требуемой точностью. Также был предложен метод оценки качества сгенерированных данных.

Предложенный метод позволяет получать реалистичные данные изменения киберфизических параметров под воздействием атаки. Кроме того, данный метод является вычислительно достаточно простым и не потребует значительных вычислительных мощностей.

Метод позволяет быстро получать правдоподобные данные, при этом можно проводить их модификацию при необходимости.

В дальнейшем планируется проверить качество обучения нейронной сети на полученных данных, а также разработать нейронную сеть, способную самостоятельно генерировать данные.

Исследование выполнено за счет гранта Российского научного фонда № 22-11-00184, <https://rscf.ru/project/22-11-00184/>.

Литература

1. Eldefrawy M.H., Khan M.K., Alghathbar K. and Cho E.-S. Broadcast authentication for wireless sensor networks using nested hashing and the Chinese remainder theorem // *Sensors*. 2010. vol. 10. no. 9. pp. 8683-8695.
2. Strohmeier M., Lenders V., Martinovic I. On the Security of the Automatic Dependent Surveillance-Broadcast Protocol // *IEEE Communications Surveys & Tutorials*. 2015. vol. 17. no. 2. pp. 1066-1087. doi: 10.1109/COMST.2014.2365951.
3. Manesh M.R., Kaabouch N. Cyber-attacks on unmanned aerial system networks: Detection countermeasure and future research directions // *Computers & Security*. 2019. vol. 85. pp. 386-401.
4. Wang S., Wang J., Su C., Ma X. Intelligent detection algorithm against UAVs' GPS spoofing attack // *IEEE 26th International Conference on Parallel and Distributed Systems (ICPADS)*. 2020. pp. 382-389.
5. Duo B., Luo J., Li Y., Hu H., Wang Z. Joint trajectory and power optimization for securing UAV communications against active eavesdropping // *China Communications*. 2021. vol. 18. no. 1. pp. 88-99. doi: 10.23919/JCC.2021.01.008.
6. Wang Q., Dai H.-N., Wang H., Xu G., Sangaiah A.K. UAV-enabled friendly jamming scheme to secure industrial Internet of Things // *Journal of Communications and Networks*. 2019. vol. 21. no. 5. pp. 481-490. doi: 10.1109/JCN.2019.000042.
7. Zhang R., Condomines J.-P., Lochin E. A Multifractal Analysis and Machine Learning Based Intrusion Detection System with an Application in a UAS/RADAR System // *Drones*, 2022. vol. 6. p. 21. URL: <https://doi.org/10.3390/drones6010021> (дата обращения: 25.07.2022).
8. Condomines J., Zhang R., Larrieu N. Network intrusion detection system for UAV ad-hoc communication: From methodology design to real test validation // *Ad Hoc Networks*, 2018. vol. 90. URL: doi: 10.1016/j.adhoc.2018.09.004 (дата обращения: 25.07.2022).
9. Talaei K.T., Ismail. S., Kaabouch N. Dynamic Selection Techniques for Detecting GPS Spoofing Attacks on UAVs // *Sensors*, 2022. vol. 22. p. 662. URL: <https://doi.org/10.3390/s22020662> (дата обращения: 25.07.2022).
10. Aissou G., Slimane H.O., Benouadah S., Kaabouch N. Tree-based Supervised Machine Learning Models For Detecting GPS Spoofing Attacks on UAS // *2021 IEEE 12th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)*, 2021. pp. 0649-0653. doi: 10.1109/UEMCON53757.2021.9666744.
11. Aissou G., Benouadah S., El Alami H., Kaabouch N. Instance-based Supervised Machine Learning Models for Detecting GPS Spoofing Attacks on UAS // *2022 IEEE 12th Annual Computing and Communication Workshop and Conference (CCWC)*, 2022. pp. 0208-0214. doi: 10.1109/CCWC54503.2022.9720888.
12. Whelan J., Sangarapillai T., Minawi O., Almeahdi A., El-Khatib K. Novelty-based Intrusion Detection of Sensor Attacks on Unmanned Aerial Vehicles // *Proceedings of*

- the 16th ACM Symposium on QoS and Security for Wireless and Mobile Networks, 2020. pp. 23–28. doi:10.1145/3416013.3426446.
13. Tippenhauer N.O., Pöpper C., Rasmussen K.B., Capkun S. On the requirements for successful GPS spoofing attacks // Proceedings of the 18th ACM conference on Computer and communications security, 2011. pp. 75–86
 14. Kerns A.J., Shepard D.P., Bhatti J.A., Humphreys T.E. Unmanned aircraft capture and control via GPS spoofing // Journal of Field Robotics. 2014. vol. 31(4). pp. 617–636.
 15. Basan E., Makarevich O., Lapina M., Mecella M. Analysis of the Impact of a GPS Spoofing Attack on a UAV // CEUR Workshop Proceedings, 2022. vol. 3094. pp. 6–16.
 16. Park K.H., Park E., Kim H.K. Unsupervised Intrusion Detection System for Unmanned Aerial Vehicle with Less Labeling Effort // You. I. (eds) Information Security Applications. WISA 2020. Lecture Notes in Computer Science. Springer. Cham, 2020. vol. 12583. URL: <https://doi.org/10.1007/978-3-030-65299-9> (дата обращения: 25.07.2022).
 17. Bekmezci I., Senturk E., Turker T. Security issues in Flying Adhoc Networks (FANETs) // Journal of Aeronautics and Space Technologies. 2016. vol. 9. no. 2. pp. 13–21.
 18. Li C., Wang X. Jamming research of the UAV GPS/INS integrated navigation system based on trajectory cheating. // 9th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), 2016. pp. 1113–1117. doi:10.1109/CISP-BMEI.2016.7852880.
 19. Schmidt D., Radke K., Camepe S., Foo E., Ren M. A survey and analysis of the GNSS spoofing threat and countermeasures // ACM Computing Surveys (CSUR), 2016. vol. 48. no. 4. pp. 64–69.
 20. Basan E., Basan A., Nekrasov A., Fridge C., Gamec J., Gamcová M. A Self-Diagnosis Method for Detecting UAV Cyber Attacks Based on Analysis of Parameter Changes // Sensors, 2021. vol. 21. p. 509. URL: <https://doi.org/10.3390/s21020509> (дата обращения: 25.07.2022).
 21. Basan E., Basan A., Nekrasov A., Fridge C., Sushkin N., Peskova O. GPS-Spoofing Attack Detection Technology for UAVs Based on Kullback–Leibler Divergence. // Drones, 2022. № 6 (1). URL: <https://doi.org/10.3390/drones6010008> (дата обращения: 25.07.2022).
 22. Cunningham R.K., Lippmann R.P., Fried D.J., Garfinkel S.L., Graf. I., Kendall K.R. Evaluating Intrusion Detection Systems Without Attacking your Friends: The 1998 DARPA Intrusion Detection Evaluation (Lexington Lincoln Lab: Massachusetts Institute of Technology) URL: <https://scholar.google.com/scholar?q=Cunningham+RK%2C+Lippmann+RP%2C+Fried+DJ%2C+Garfinkel+SL%2C+Graf+I+and+Kendall+KR+1998+Evaluating+Intrusion+Detection+Systems+Without+Attacking+your+Friends%3A+The+1998+DARPA+Intrusion+Detection+Evaluation+%28Lexington+Lincoln+Lab%3A+Massachusetts+Institute+of+Technology%29> (дата обращения: 25.08.2022).
 23. Tavallae M., Bagheri E., Lu W., Ghorbani A.A. A Detailed Analysis of the KDD CUP 99 Data Set // 2009 IEEE Symposium on Computational Intelligence for Security and Defense Applications, 2009. URL: <https://scholar.google.com/scholar?q=Tavallae+M%2C+Bagheri+E%2C+Lu+W+and+Ghorbani+AA+2009+A+Detailed+Analysis+of+The+KDD+CUP+99+Data+Set+2009+IEEE+Symposium+on+Computational+Intelligence+for+Security+and+Defense+Applications%2C+IEEE> (дата обращения: 25.08.2022).
 24. Uramová J., Segeč P., Moravčík M., Papán J., Kontšek M., Hrabovský J. Infrastructure for generating new ids dataset // 2018 16th International Conference on Emerging eLearning Technologies and Applications (ICETA), 2018. pp. 603–610.

25. Nadiah N., Yusof M., Sulaiman N.S. Cyber Attack Detection Dataset: A Review // 2022 J. Phys.: Conf. Ser. 2319 012029 URL: <https://iopscience.iop.org/article/10.1088/1742-6596/2319/1/012029> (дата обращения: 25.08.2022).
26. Martins N., Cruz J.M., Cruz T., Abreu P.H. Adversarial machine learning applied to intrusion and malware scenarios: a systematic review// IEEE Access, 2020. vol. 8. pp. 35403– 35419. URL: <https://doi.org/10.1109/access.2020.2974752> (дата обращения: 25.08.2022).
27. Koroniotis N., Moustafa N., Sitnikova E., Turnbull B. Towards the development of realistic botnet dataset in the internet of things for network forensic analytics: Bot-IoT dataset // Futur Gener Comput. Syst, 2019. vol. 100. pp.-779–96. URL: <https://doi.org/10.1016/j.future.2019.05.041>. (дата обращения: 25.08.2022).
28. Martins N., Cruz J.M., Cruz T., Abreu P.H. Analyzing the footprint of classifiers in adversarial denial of service contexts. // Progress in artificial intelligence. Berlin: Springer International Publishing, 2019. pp. 256–67. URL: https://doi.org/10.1007/978-3-030-30244-3_22. (дата обращения: 25.08.2022).
29. Alshaibi A., Al-Ani. M., Al-Azzawi A., Konev A., Shelupanov A. The Comparison of Cybersecurity Datasets // Data, 2022. vol. 7. p. 22. URL: <https://doi.org/10.3390/data7020022> (дата обращения: 25.08.2022).
30. Goswami G., Agarwal A., Ratha N., Singh R., Vatsa M. Detecting and Mitigating Adversarial Perturbations for Robust Face Recognition // Int. J. Comput. Vis., 2019. vol. 127. pp. 719–742.
31. Warzynski A., Kolaczek G. Intrusion detection systems vulnerability on adversarial examples // Innov. Intell. Syst. Appl. (INISTA), 2018. URL: <https://doi.org/10.1109/inista.2018.8466271>. (дата обращения: 25.08.2022).
32. Rahim R., Ahanger A.S., Khan S.M., Masoodi F. Analysis of IDS using Feature Selection Approach on NSL-KDD Dataset 2021 // Raju Pal & Praveen K. Shukla (eds.), SCRS Conference Proceedings on Intelligent Systems, 2021. pp. 475–481. URL: <https://doi.org/10.52458/978-93-91842-08-6-45> (дата обращения: 25.08.2022).
33. Hu W. et al. AdaBoost-Based Algorithm for Network // IEEE Transactions on Systems, Man, and Cybernetics. 2008. 38 (2). pp. 577–583.
34. Moustafa N., Slay J. UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set) // Mil Commun Inf Syst Conf (MilCIS), 2015. URL: <https://doi.org/10.1109/milcis.2015.7348942>. (дата обращения: 25.08.2022).
35. Pacheco Y., Sun W. Adversarial machine learning: A comparative study on contemporary intrusion detection datasets. // August 2022 SN Computer Science. 2022. № 3(5). pp. 160–171. doi: 10.1007/s42979-022-01321-8.
36. Sharafaldin I., Gharib A., Lashkari A.H., Ghorbani A.A. Towards a Reliable Intrusion Detection Benchmark Dataset // Softw. Netw. vol. 2017(1). pp. 177–200.
37. Sharafaldin I., Lashkari A.H., Ghorbani A.A. Toward Generating a New Intrusion Detection Dataset and Intrusion Traffic Characterization // Proceedings of the 4th International Conference on Information Systems Security and Privacy, 2018. vol. 1. pp. 108–116.

Басан Елена Сергеевна — канд. техн. наук, доцент, кафедра безопасности информационных технологий, Южный федеральный университет. Область научных интересов: разработка и исследование технологий обнаружения атак и вторжений, обнаружение аномального поведения, безопасность робототехнических систем, анализ угроз и уязвимостей. Число научных публикаций — 99. ebasan@sfdedu.ru; улица Чехова, 2, 347922, Таганрог, Россия; р.т.: +7(951)520-5488.

Пескова Ольга Юрьевна — канд. техн. наук, доцент, кафедра безопасности информационных технологий, Южный федеральный университет. Область научных интересов: информационная безопасность. Число научных публикаций — 206. ouyureskova@sfnedu.ru; улица Чехова, 2, 347922, Таганрог, Россия; р.т.: +7(8634)371-905.

Силин Олег Игоревич — студент, Южный федеральный университет. Область научных интересов: разработка и исследование технологий обнаружения атак и вторжений, расследование инцидентов, беспилотные летательные аппараты, оценка рисков. Число научных публикаций — 5. silin@sfnedu.ru; улица Чехова, 2, 347922, Таганрог, Россия; р.т.: +7(928)326-4256.

Басан Александр Сергеевич — канд. техн. наук, доцент, Южный федеральный университет. Область научных интересов: разработка и исследование технологий обнаружения атак и вторжений, обнаружение аномального поведения, безопасность робототехнических систем, анализ угроз и уязвимостей. Число научных публикаций — 99. asbasan@sfnedu.ru; улица Чехова, 2, 347922, Таганрог, Россия; р.т.: +7(988)537-0968.

Абрамов Евгений Сергеевич — канд. техн. наук, доцент, заведующий кафедрой, кафедра безопасности информационных технологий, Южный федеральный университет. Область научных интересов: технологии обнаружения сетевых атак, модели атак, технологии threat intelligence, применение методов искусственного интеллекта в информационной безопасности. Число научных публикаций — 80. abramoves@sfnedu.ru; улица Чехова, 2, 347922, Таганрог, Россия; р.т.: 7(863)371-905.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда № 22-11-00184, <https://rscf.ru/project/22-11-00184/>.

E. BASAN, O. PESKOVA, O. SILIN, A. BASAN, E. ABRAMOV
**DATA GENERATION FOR MODELING ATTACKS ON UAVS FOR
THE PURPOSE OF TESTING INTRUSION DETECTION SYSTEMS**

Basan E., Peskova O., Silin O., Basan A., Abramov E. Data Generation for Modeling Attacks on UAVs for the Purpose of Testing Intrusion Detection Systems.

Abstract. Today, issues related to ensuring the safety of UAVs are very relevant. Researchers need to develop new protection methods to detect attacks in a timely manner and implement mitigation measures. The authors propose a new concept of attack detection "from inside" the UAV. The idea is to analyze the cyber-physical parameters of the UAV, which may indicate an attack, and its possible consequences. It was determined that to detect an attack and determine the consequences to which it can lead, it is necessary to control not only the initial parameters, but also the internal cyber-physical parameters of the UAV. This will allow predicting the possible consequences of an attack and taking emergency measures. A scheme of the impact of an attack on UAVs and the relationship with security incidents, built using an ontological approach, has been worked out. Two main essences of the UAV are considered - the physical and digital aspects of the UAV. Examples of chains of attacks leading to various consequences are also shown. In the review part, the analysis of methods and algorithms for detecting spoofing attacks using data generators is carried out, based on which conclusions are drawn about their advantages and disadvantages. Further, based on the experiments performed, the authors propose a method for assessing the quality of data and a method for generating anomalous data sets similar to real attack data, which can be used to develop and test methods for detecting and blocking attacks. The architecture of the experimental stand, which was used in the framework of full-scale simulation, is described. At this stand, designed to parse GPS spoofing attacks (GPS spoofing), several scenarios of a normal flight, and then several attack scenarios, were tested. Based on the results of the experiments, a method has been proposed that allows simulating the data corresponding to the attack with the required accuracy. A method for assessing the quality of fake data has also been proposed.

Keywords: data analysis, statistics, attacks, risks, UAVs.

References

1. Eldefrawy M.H., Khan M.K., Alghathbar K., Cho E.-S. Broadcast authentication for wireless sensor networks using nested hashing and the Chinese remainder theorem. *Sensors*. 2010. vol. 10. no. 9. pp. 8683-8695.
2. Strohmeier M., Lenders V., Martinovic I. On the Security of the Automatic Dependent Surveillance-Broadcast Protocol. *IEEE Communications Surveys & Tutorials*, 2015. vol. 17. no. 2. pp. 1066-1087. doi: 10.1109/COMST.2014.2365951.
3. Manesh M.R., Kaabouch N. Cyber-attacks on unmanned aerial system networks: Detection countermeasure and future research directions. *Computers & Security*. 2019. vol. 85. pp. 386-401.
4. Wang S., Wang J., Su C., Ma X. Intelligent detection algorithm against UAVs' GPS spoofing attack. *IEEE 26th International Conference on Parallel and Distributed Systems (ICPADS)*, 2020. pp. 382-389.
5. Duo B., Luo J., Li Y., Hu H., Wang Z. Joint trajectory and power optimization for securing UAV communications against active eavesdropping. *China Communications*. 2021. vol. 18. no. 1. pp. 88-99. doi: 10.23919/JCC.2021.01.008.

6. Wang Q., Dai H.-N., Wang H., Xu G., Sangaiah A.K. UAV-enabled friendly jamming scheme to secure industrial Internet of Things. *Journal of Communications and Networks*. 2019. vol. 21. no. 5. pp. 481-490. doi: 10.1109/JCN.2019.000042.
7. Zhang R., Condomines J.-P., Lochin E. A Multifractal Analysis and Machine Learning Based Intrusion Detection System with an Application in a UAS/RADAR System. *Drones*, 2022. vol. 6. p. 21. URL: <https://doi.org/10.3390/drones6010021> (accessed 25.07.2022).
8. Condomines J., Zhang R., Larrieu N. Network intrusion detection system for UAV ad-hoc communication: From methodology design to real test validation. *Ad Hoc Networks*, 90. URL: <https://doi.org/10.1016/j.adhoc.2018.09.004> (accessed 25.07.2022).
9. Talaci K.T., Ismail S., Kaabouch N. Dynamic Selection Techniques for Detecting GPS Spoofing Attacks on UAVs. *Sensors* 2022, vol. 22. p. 662. URL: <https://doi.org/10.3390/s22020662> (accessed 25.07.2022).
10. Aissou G., Slimane H.O., Benouadah S., Kaabouch N. Tree-based Supervised Machine Learning Models For Detecting GPS Spoofing Attacks on UAS. 2021 IEEE 12th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON), 2021. doi: 10.1109/UEMCON53757.2021.9666744. pp. 0649-0653.
11. Aissou G., Benouadah S., El Alami H., Kaabouch N. Instance-based Supervised Machine Learning Models for Detecting GPS Spoofing Attacks on UAS. 2022 IEEE 12th Annual Computing and Communication Workshop and Conference (CCWC), 2022. pp. 0208-0214. doi: 10.1109/CCWC54503.2022.9720888.
12. Whelan J., Sangarapillai T., Minawi O., Almechadi A., El-Khatib K. Novelty-based Intrusion Detection of Sensor Attacks on Unmanned Aerial Vehicles. *Proceedings of the 16th ACM Symposium on QoS and Security for Wireless and Mobile Networks*, 2020. pp. 23–28. doi: 10.1145/3416013.3426446.
13. Tippenhauer N.O., Pöpper C., Rasmussen K.B., Capkun S. On the requirements for successful GPS spoofing attacks. *Proceedings of the 18th ACM conference on Computer and communications security*, 2011. pp. 75–86
14. Kerns A.J., Shepard D.P., Bhatti J.A., Humphreys T.E. Unmanned aircraft capture and control via GPS spoofing. *Journal of Field Robotics*. 2014. vol 31(4). pp. 617–636.
15. Basan E., Makarevich O., Lapina M., Mecella M. Analysis of the Impact of a GPS Spoofing Attack on a UAV. *CEUR Workshop Proceedings*, 2022. vol. 3094. pp. 6–16.
16. Park K.H., Park E., Kim H.K. Unsupervised Intrusion Detection System for Unmanned Aerial Vehicle with Less Labeling Effort. You. I. (eds) *Information Security Applications. WISA 2020. Lecture Notes in Computer Science*. Springer. Cham, 2020. vol 12583. URL: <https://doi.org/10.1007/978-3-030-65299-9> (accessed 25.07.2022).
17. Bekmezci I., Senturk E., Turker T. Security issues in Flying Adhoc Networks (FANETs). *Journal of Aeronautics and Space Technologies*. 2016. vol. 9. no. 2. pp. 13-21.
18. Li C., Wang X. Jamming research of the UAV GPS/INS integrated navigation system based on trajectory cheating. 9th International Congress on Image and Signal Processing, BioMedical, Engineering and Informatics (CISP-BMEI), 2016. pp. 1113-1117. doi: 10.1109/CISP-BMEI.2016.7852880.
19. Schmidt D., Radke K., Camtepe S., Foo E., Ren M. A survey and analysis of the GNSS spoofing threat and countermeasures. *ACM Computing Surveys (CSUR)*. 2016. vol. 48. no. 4. pp. 64-69.
20. Basan E., Basan A., Nekrasov A., Fidge C., Gamec J., Gamcová M. A Self-Diagnosis Method for Detecting UAV Cyber Attacks Based on Analysis of Parameter Changes.

- Sensors 2021. 2021. vol. 21. p. 509. URL: <https://doi.org/10.3390/s21020509> (accessed 25.07.2022).
21. Basan E., Basan A., Nekrasov A., Fidge C., Sushkin N., Peskova O. GPS-Spoofing Attack Detection Technology for UAVs Based on Kullback–Leibler Divergence. *Drones*, 2022. № 6 (1). URL: <https://doi.org/10.3390/drones6010008> (accessed 25.07.2022).
 22. Cunningham R.K., Lippmann R.P., Fried D.J., Garfinkel S.L., Graf I., Kendall K.R. Evaluating Intrusion Detection Systems Without Attacking your Friends: The 1998 DARPA Intrusion Detection Evaluation (Lexington Lincoln Lab: Massachusetts Institute of Technology). URL: <https://scholar.google.com/scholar?q=Cunningham+RK%2C+Lippmann+RP%2C+Fried+DJ%2C+Garfinkel+SL%2C+Graf+I+and+Kendall+KR+1999+Evaluating+Intrusion+Detection+Systems+Without+Attacking+your+Friends%3A+The+1998+DARPA+Intrusion+Detection+Evaluation+%28Lexington+Lincoln+Lab%3A+Massachusetts+Institute+of+Technology%29> (accessed: 25.08.2022).
 23. Tavallaee M., Bagheri E., Lu W., Ghorbani A.A. A Detailed Analysis of the KDD CUP 99 Data Set. 2009 IEEE Symposium on Computational Intelligence for Security and Defense Applications, 2009. URL: <https://scholar.google.com/scholar?q=Tavallaee+M%2C+Bagheri+E%2C+Lu+W+and+Ghorbani+AA+2009+A+Detailed+Analysis+of+The+KDD+CUP+99+Data+Set+2009+IEEE+Symposium+on+Computational+Intelligence+for+Security+and+Defense+Applications%2C+IEEE> (accessed: 25.08.2022).
 24. Uramová J., Segeč P., Moravčík M., Papán J., Kontšek M., Hrabovský J. Infrastructure for generating new ids dataset. 2018 16th International Conference on Emerging eLearning Technologies and Applications (ICETA), 2018. pp. 603–610.
 25. Nadiah N., Yusof M., Sulaiman N.S. Cyber Attack Detection Dataset: A Review // 2022 J. Phys.: Conf. Ser. 2319 012029 URL: <https://iopscience.iop.org/article/10.1088/1742-6596/2319/1/012029> (accessed: 25.08.2022).
 26. Martins N., Cruz J.M., Cruz T., Abreu P.H. Adversarial machine learning applied to intrusion and malware scenarios: a systematic review. *IEEE* 2020. vol. 8. pp. 35403–35419. URL: <https://doi.org/10.1109/access.2020.2974752> (accessed: 25.08.2022).
 27. Koroniotis N., Moustafa N., Sitnikova E., Turnbull B. Towards the development of realistic botnet dataset in the internet of things for network forensic analytics: Bot-IoT dataset. *Futur Gener Comput. Syst*, 2019. vol. 100. pp. 779–796. URL: <https://doi.org/10.1016/j.future.2019.05.041>. (accessed: 25.08.2022).
 28. Martins N., Cruz J.M., Cruz T., Abreu P.H. Analyzing the footprint of classifiers in adversarial denial of service contexts. *Progress in artificial intelligence*. Berlin: Springer International Publishing, 2019. pp. 256–67. URL: https://doi.org/10.1007/978-3-030-30244-3_2210.1007/978-3-030-30244-3_22. (accessed: 25.08.2022).
 29. Alshaibi A., Al-Ani M., Al-Azzawi A., Konev A., Shelupanov A. The Comparison of Cybersecurity Datasets. *Data*, 2022. vol. 7. p. 22. URL: <https://doi.org/10.3390/data7020022> (accessed: 25.08.2022).
 30. Goswami G., Agarwal A., Ratha N., Singh R., Vatsa M. Detecting and Mitigating Adversarial Perturbations for Robust Face Recognition. *Int. J. Comput. Vis.*, 2019. vol. 127. pp. 719–742.
 31. Warzynski A., Kolaczek G. Intrusion detection systems vulnerability on adversarial examples. *Innov Intell Syst Appl (INISTA)*, 2018. URL: <https://doi.org/10.1109/inista.2018.8466271>. (accessed: 25.08.2022).
 32. Rahim R., Ahanger A.S., Khan S.M., Masoodi F. Analysis of IDS using Feature Selection Approach on NSL-KDD Dataset 2021. Raju Pal & Praveen K. Shukla (eds.),

- SCRS Conference Proceedings on Intelligent Systems, 2021. pp. 475–481. URL: <https://doi.org/10.52458/978-93-91842-08-6-45> (accessed: 25.08.2022).
33. Hu W. et al. AdaBoost-Based Algorithm for Network. IEEE Transactions on Systems, Man, and Cybernetics. 2008. 38(2). pp. 577–583.
 34. Moustafa N., Slay J. UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set). Mil Commun Inf Syst Conf (MilCIS), 2015. URL: <https://doi.org/10.1109/milcis.2015.7348942>. (accessed: 25.08.2022).
 35. Pacheco Y., Sun W. Adversarial machine learning: A comparative study on contemporary intrusion detection datasets. August 2022 SN Computer Science. 2022. № 3(5). pp. 160–171. doi: 10.1007/s42979-022-01321-8
 36. Sharafaldin I., Gharib A., Lashkari A.H., Ghorbani A.A. Towards a Reliable Intrusion Detection Benchmark Dataset. Softw. Netw. vol. 2017(1). pp. 177–200.
 37. Sharafaldin I., Lashkari A.H., Ghorbani A.A. Toward Generating a New Intrusion Detection Dataset and Intrusion Traffic Characterization. Proceedings of the 4th International Conference on Information Systems Security and Privacy. 2018. vol. 1. pp. 108–116.

Basan Elena — Ph.D., Associate professor, Department of information technology security, Southern Federal University. Research interests: development and research of attack and intrusion detection technologies, abnormal behavior detection, security of robotic systems, analysis of threats and vulnerabilities. The number of publications — 99. ebasan@sfedu.ru; 2, Chekhov St., 347922, Taganrog, Russia; office phone: +7(951)520-5488.

Peskova Olga — Ph.D., Associate professor, Department of information technology security, Southern Federal University. Research interests: information security. The number of publications — 206. oyupeskova@sfedu.ru; 2, Chekhov St., 347922, Taganrog, Russia; office phone: +7(8634)371-905.

Silin Oleg — Student, Southern Federal University. Research interests: development and research of attack and intrusion detection technologies, incident investigation, unmanned aerial vehicles, risk assessment. The number of publications — 5. silin@sfedu.ru; 2, Chekhov St., 347922, Taganrog, Russia; office phone: +7(928)326-4256.

Basan Alexander — Ph.D., Associate professor, Southern Federal University. Research interests: development and research of attack and intrusion detection technologies, abnormal behavior detection, security of robotic systems, analysis of threats and vulnerabilities. The number of publications — 99. asbanan@sfedu.ru; 2, Chekhov St., 347922, Taganrog, Russia; office phone: +7(988)537-0968.

Abramov Evgeniy — Ph.D., Associate Professor, Head of department, Department of information technology security, Southern Federal University. Research interests: network attack detection technologies, attack models, threat intelligence technologies, application of artificial intelligence methods in information security. The number of publications — 80. abramoves@sfedu.ru; 2, Chekhov St., 347922, Taganrog, Russia; office phone: 7(863)371-905.

Acknowledgements. The research was supported by the Russian Science Foundation grant No. 22-11-00184, <https://rscf.ru/project/22-11-00184/>.

И.В. КОТЕНКО, И.Б. САЕНКО, О.С. ЛАУТА, А.М. КРИБЕЛЬ
**МЕТОДИКА ОБНАРУЖЕНИЯ АНОМАЛИЙ И КИБЕРАТАК НА
ОСНОВЕ ИНТЕГРАЦИИ МЕТОДОВ ФРАКТАЛЬНОГО
АНАЛИЗА И МАШИННОГО ОБУЧЕНИЯ**

Котенко И.В., Саенко И.Б., Лаута О.С., Крибель А.М. Методика обнаружения аномалий и кибератак на основе интеграции методов фрактального анализа и машинного обучения.

Аннотация. В современных сетях передачи данных для постоянного мониторинга сетевого трафика и обнаружения в нем аномальной активности, а также идентификации и классификации кибератак, необходимо учитывать большое число факторов и параметров, включая возможные сетевые маршруты, времена задержки данных, потери пакетов и новые свойства трафика, отличающиеся от нормальных. Все это является побудительным мотивом к поиску новых методов и методик обнаружения кибератак и защиты от них сетей передачи данных. В статье рассматривается методика обнаружения аномалий и кибератак, предназначенная для использования в современных сетях передачи данных, которая основывается на интеграции методов фрактального анализа и машинного обучения. Методика ориентирована на выполнение в реальном или близком к реальному масштабе времени и включает несколько этапов: (1) выявления аномалий в сетевом трафике, (2) идентификации в аномалиях кибератак и (3) классификации кибератак. Первый этап реализуется с помощью методов фрактального анализа (оценки самоподобия сетевого трафика), второй и третий – с применением методов машинного обучения, использующих ячейки рекуррентных нейронных сетей с долгой краткосрочной памятью. Рассматриваются вопросы программной реализации предлагаемой методики, включая формирование набора данных, содержащего сетевые пакеты, циркулирующие в сети передачи данных. Представлены результаты экспериментальной оценки предложенной методики, полученные с использованием сформированного набора данных. Результаты экспериментов показали достаточно высокую эффективность предложенной методики и разработанных для нее решений, позволяющих осуществлять раннее обнаружение как известных, так и неизвестных кибератак.

Ключевые слова: кибератака, фрактальный анализ, показатель Херста, машинное обучение, LSTM.

1. Введение. Мировые тенденции в области информатизации и связи на базе цифровых методов передачи, обработки, хранения, представления и защиты информации заключаются во взаимном проникновении и «сращивании» информационных и телекоммуникационных систем не только на уровне технологий их разработки и эксплуатации, но и их структурного и функционального объединения. При этом широко используется термин «сеть передачи данных» (СПД).

Интеграция и конвергенция сетей и служб связи в современных СПД обеспечивает доступ пользователей к любой услуге связи за счет гибких возможностей по их обработке и управлению. По этой

причине, с одной стороны, повышаются эффективность СПД, в том числе устойчивость функционирования СПД, и экономическая выгода от использования СПД. С другой стороны, это предоставляет злоумышленникам возможность воздействовать на СПД путем реализации кибератак (КА).

Воздействие КА возможно за счет массового использования устаревших операционных систем, малоэффективных механизмов защиты и наличия множественных уязвимостей в незащищенных сетевых протоколах. Используя подобные уязвимости, злоумышленники могут изменять настройки сетевых устройств, прослушивать и перенаправлять трафик, блокировать сетевое взаимодействие и получать несанкционированный доступ к внутренним компонентам СПД.

Воздействие КА приводит к появлению в сетевом трафике аномальной активности [1, 2]. Для постоянного мониторинга сетевого трафика и обнаружения в нем аномальной активности, идентификации и классификации атак, а также выявления в нем ложных изменений необходимо учитывать наличие большого количества параметров, характеризующих проявление новых свойств трафика. Однако при этом остается необходимость обеспечения высокого качества обслуживания приложений. Все это является побудительным мотивом для поиска новых методов и методик обнаружения КА и защиты от них СПД. К их числу можно отнести предлагаемую в настоящей статье методику, основанную на интеграции методов фрактального анализа и машинного обучения. Методы фрактального анализа позволяют оперативно выявлять аномальный трафик, а методы машинного обучения обеспечивают идентификацию, классификацию и прогнозирование КА.

Ключевым параметром фрактального анализа является показатель Херста, или показатель масштабирования (scaling). Эту меру, как правило, используют при анализе временных рядов. Чем больше задержка между двумя одинаковыми парами значений во временном ряду, тем меньше показатель Херста. При этом выдвигается гипотеза, что для нахождения показателя Херста достаточно знать, стационарен исследуемый процесс или нет. От этого зависит выбор алгоритма для дальнейшего вычисления данного показателя.

Анализ показал, что одним из достаточно эффективных методов идентификации, классификации и прогнозирования КА является использование искусственных нейронных сетей типа LSTM (Long Short-Term Memory). Свойство рекуррентности, присущее нейронным

сетям LSTM, позволяет им «обращаться» к результатам своей работы в прошлом и делать анализ предсказаний. Тем самым контекст решений по выработке мероприятий по защите от КА в будущем будет зависеть не только от первичного обучения сетей LSTM, но и от их дальнейшей работы в потоке поступающих данных [3].

Таким образом, с целью идентификации и классификации КА сначала следует определить, является трафик стационарным или нестационарным. Далее следует рассчитать показатель Херста и определить наличие в трафике свойства самоподобия. Изменение значения показателя Херста говорит о появлении в сетевом трафике аномалий, вызванных КА. На дальнейших этапах происходит идентификация и классификация КА, а также выработка мероприятий по защите СПД с применением LSTM [4, 5].

В настоящее время вопросы, связанные с изучением самоподобных свойств временных рядов и их практическим применением в различных системах мониторинга, находятся в фокусе внимания многих исследователей. Так, в [6–8] для выявления закономерностей во временных рядах использовался метод R/S-анализа (rescaled range analysis). В [9] моделировался и исследовался на самоподобие трафик VoIP (Voice Over Internet Protocol). В [10–12] изучался не только показатель Херста, но и фрактальная размерность. В [13, 14] было дано объяснение, почему телекоммуникационный трафик обладает фрактальными свойствами.

При этом следует отметить, что существует мало практических экспериментов, направленных на изучение фрактальных свойств трафика. Среди такого рода исследований можно выделить работы [15–17]. Однако в [15] трафик рассматривается не в СПД, а в радиоволнах, передаваемых сотовыми станциями. В [18–20] исследователи пришли к выводу о самоподобии транспортного трафика. При этом они полагались исключительно на визуальные знаки, отыскивая на графиках похожие участки и выдавая их за самоподобные процессы.

Одним из первых исследований, в котором было обращено внимание на свойство самоподобия трафика СПД, является работа [9]. Кроме того, следует указать ряд исследований, в которых аномалии сетевого трафика и КА определяются на основе оценки энтропии [21–24], а также применения методов машинного обучения [25–33].

Так, в [21] предложен алгоритм для обнаружения резких изменений во временных рядах энтропии сети, который непрерывно проводит краткосрочные прогнозы, определяет разницу между прогнозами и фактическим наблюдаемым значением энтропии. Чем

выше разница, тем более резким является изменение. В [22] для обнаружения атак используется подход, основанный на энтропии всех полезных атрибутов сетевых пакетов во время КА. В [23] эмпирически оценивается энтропия Хартли, энтропия Шеннона, энтропия Реньи и обобщенная энтропия. В работе [24] предложен инструмент для внедрения аномалий в заданную трассировку потока. Этот инструмент был апробирован для внедрения аномалий, образованных от следующий трех типов КА: сканировании сети, смещение входа и отказ в обслуживании. Однако указанные работы направлены на обнаружение только тех КА, которые приводят к резкому изменению в сетевом трафике СПД (например, DDoS, черви и сканирование сети).

В [25] рассматривается метод обнаружения аномалий трафика сети и классификации КА, основанный на использовании многослойной нейронной сети состояния эхо-сигнала. При этом используются результаты вычисления статистического распределения и корреляции характеристик сетевого потока. В работе [26] для обнаружения КА сетевой поток размечается и преобразуется в последовательности «слов», которые формируют «предложения», отражающие взаимодействие между компьютерами. Далее с применением рекуррентной нейронной сети с долгой краткосрочной памятью изучается семантическая и синтаксическая грамматика предлагаемого языка для прогнозирования связи между двумя IP-адресами, причем ошибка прогнозирования используется в качестве показателя того, насколько типичны или нетипичны наблюдаемые коммуникации.

Преимущества методов машинного обучения перед другими методами обнаружения сетевых атак были рассмотрены в работе [27] на примере следующих методов: деревья решений; байесовские сети; сплайны; алгоритмы кластеризации и регрессии. Показано, что они обладают возможностями обнаруживать не только аномалии, но и злоупотребления. В [28] предлагается в целях повышения эффективности обнаружения сетевых атак комплексировать нейронные, иммунные и нейро-нечеткие классификаторы.

В [29] показано, что за последние 10 лет машинное обучение стало играть еще большую роль в многочисленных приложениях кибербезопасности. Они защищают киберпространство от атак, позволяют обнаруживать вторжения, спам и вредоносные программы. При этом следует отметить, что методы машинного обучения – это не обязательно нейронные сети. К числу наиболее известных и популярных методов машинного обучения по-прежнему относятся Support Vector Machine (SVM) («машина опорных векторов») [30],

Random Forest (RF) («случайный лес») [31], Decision Tree («дерево решений») [32], k-Nearest Neighbors (« k ближайших значений») [33] и многие другие. Некоторые из перечисленных методов будут использованы и исследованы в настоящей работе.

Таким образом, настоящая работа, с одной стороны, опирается на достигнутые успехи в исследовании самоподобных свойств трафика СПД. С другой стороны, она развивает известные решения в направлении создания методики, позволяющей обнаруживать аномалии сетевого трафика, вызванные КА.

Целью настоящей работы является разработка методики обнаружения аномалий и КА, основывающейся на интеграции методов фрактального анализа и машинного обучения и позволяющей за счет этого достигнуть достаточно высоких скорости и точности обнаружения как известных, так и неизвестных КА.

Вклад настоящей работы заключается в следующем: (1) реализован подход к обнаружению КА, основанный на анализе фрактальных свойств трафика; (2) исследованы структуры долговременных зависимостей в трафике СПД, позволяющие выявлять его характерные особенности в интересах раннего обнаружения КА; (3) обоснована структура сети LSTM, позволяющая идентифицировать и классифицировать КА с достаточно высокой вероятностью; (4) разработан программный прототип, реализующий предлагаемую методику, и сгенерирован набор данных с трафиком СПД, содержащим аномалии от воздействия как известных, так и неизвестных КА; (5) проведена экспериментальная оценка предлагаемой методики, показывающая ее достаточно высокую эффективность.

Новизна полученных результатов заключается в том, что на основе экспериментальных исследований обоснован наилучший метод определения самоподобия для нестационарных и стационарных временных рядов, позволяющий с высокой точностью и достаточно быстро обнаруживать изменения в трафике, а также определена структура сети LSTM, позволяющая с высокой точностью и достаточно быстро прогнозировать факт воздействия КА, на основе которого в дальнейшем могут вырабатываться проактивные мероприятия защиты.

2. Основные теоретические положения методики.

Собираемый сетевой трафик представляется в виде временного ряда $X = \{x_1, x_2, \dots, x_n\}$, описанного через фрактальное броуновское движение (ФБД). Случайный процесс $X(t)$, соответствующий ФБД, использует параметр Херста H , $0 \leq H \leq 1$. Приращение этого

процесса $\Delta X(\tau) = X(t + \tau) - X(t)$ имеет следующее нормальное распределение:

$$P(\Delta X(\tau) < x) = \frac{1}{\sqrt{2\pi}\delta_0\tau^{2H}} \int_{-\infty}^x \exp\left[-\frac{z^2}{2\delta_0^2\tau^{2H}}\right] dz, \quad (1)$$

где δ_0 – коэффициент диффузии.

Показатель H характеризует степень самоподобия процесса. Чем ближе этот параметр к единице, тем более ярко проявляются фрактальные свойства. Равенство $H = 0,5$ говорит об отсутствии самоподобия [1, 9, 10]. ФБД с $H = 0.5$ совпадает с классическим броуновским движением, что делает временной ряд наиболее зашумленным.

Обнаружение аномалий в сетевом трафике с помощью фрактального анализа происходит следующим образом. Вначале определяют, является ли трафик стационарным. Для этой цели используется тест Дики-Фуллера [18]. Далее вычисляется значение H одним из методов, в зависимости от того, является трафик стационарным или нет. Если трафик является стационарным, то используется метод R/S (Rescaled Range Analysis) [35]. Если трафик является нестационарным, то используется метод DFA (Detrended Fluctuation Analysis) [36]. Если значение H лежит в диапазоне $[0,5; 1]$, то трафик считается нормальным, т.е. в нем отсутствуют аномалии. В противном случае считается, что трафик является аномальным, т.е. он содержит аномалии.

Кроме методов фрактального анализа существует множество других способов, позволяющих определить аномалии во временном ряду. К числу таких методов можно отнести, например, методы авторегрессионного интегрированного скользящего среднего, кумулятивных сумм, SVM, RF и некоторые другие. Указанные методы неплохо справляются с обнаружением аномальных выбросов. При таких выбросах аномалия проявляется в виде нестационарности некоторых наблюдаемых временных рядов. Эти аномалии проявляются не только в виде мгновенных скачков амплитуды измерений, но и как медленные тренды, практически невидимые за время наблюдений. Однако при тестировании вышеуказанных алгоритмов на реальном трафике СПД оказалось, что не всегда имеющиеся в трафике выбросы являются аномальными. Поэтому в рассматриваемой методике предлагается дополнительно использовать для обнаружения аномальных выбросов метод машинного обучения, основанный на применении гибридной искусственной нейронной сети, состоящей из автокодировщика (autoencoder) и классификатора.

Под автокодировщиком понимается нейронная сеть прямого распространения, которая восстанавливает входной сигнал на выходе. Внутри у него имеется скрытый слой, который представляет собой код, описывающий некоторую модель. Автокодировщик конструируются таким образом, чтобы иметь возможность точно скопировать вход на выходе.

Обучение автокодировщика осуществляется по схеме, представленной на рисунке 1. Алгоритм обучения автокодировщика включает следующие шаги.

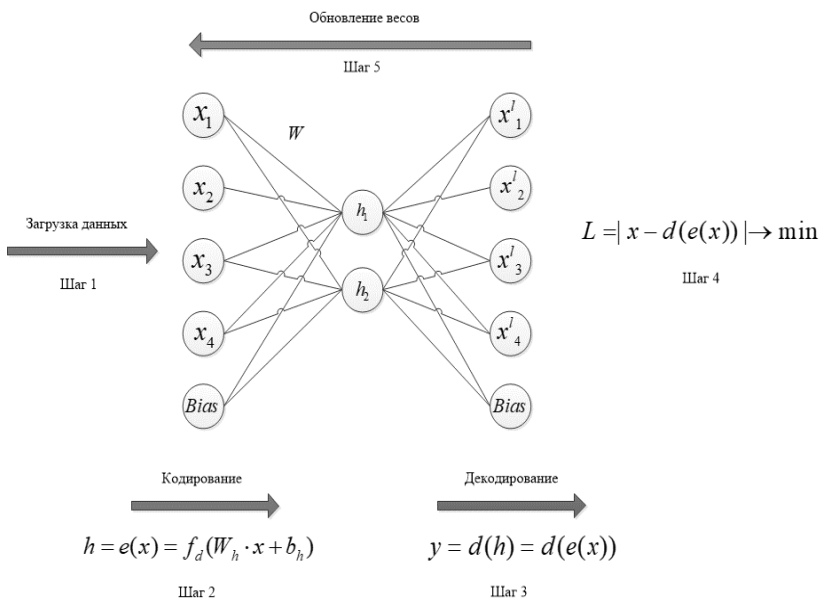


Рис. 1. Схема обучения автокодировщика

Шаг 1 (загрузка данных): входные данные x подаются на вход нейронной сети.

Шаг 2 (кодирование): кодировщик кодирует входной вектор x в вектор h меньшего размера:

$$h = e(x) = f_d(W_h \cdot x + b_h), \quad (2)$$

где f_d – функция активации (ReLU, сигмоидальная функция или гиперболический тангенс) промежуточного слоя; b_h – вектор

смещений промежуточного слоя; W_h – матрица весов промежуточного слоя.

Шаг 3 (декодирование данных): вектор h декодируется, чтобы воссоздать ввод:

$$y = d(h) = f_e(W_y \cdot h + b_y). \quad (3)$$

Параметры f_e , W_y , b_y аналогичны соответствующим параметрам входного слоя. Выход будет иметь такой же размер, что и вход.

Шаг 4 (расчет ошибки): вычисляется ошибка:

$$L = |x - d(e(x))| \rightarrow \min. \quad (4)$$

Ошибка L определяет разницу между входным и выходным вектором. Цель процедуры обучения автокодировщика заключается в минимизации этой ошибки.

Шаг 5 (обновление весов): с помощью алгоритма обратного распространения ошибки следует обновить веса $W = \{W_h, W_y\}$.

Шаги 1-5 повторяются до тех пор, пока ошибка не снизится до приемлемого результата.

После обучения автокодировщик может восстанавливать наблюдения с достаточно малой ошибкой. Однако когда он попытается предсказать/реконструировать аномальное наблюдение, он обнаружит, что никогда не видел таких последовательностей во время обучения. Таким образом, ошибка восстановления между исходными и восстановленными данными будет выше для аномальных данных, чем для обычных.

В качестве функции потерь выступает категориальная кросс-энтропия (Categorical Cross-Entropy):

$$CCE(y, p) = - \sum_{i=1}^M (y_i \cdot \log_2 p_i). \quad (5)$$

где p_i – прогнозируемая вероятность выходной метки y_i ; M – количество классов.

В случае, если $M = 2$, т.е. реализуется бинарная классификация, как в нашем случае, формула (5) преобразуется в формулу, описывающую бинарную кросс-энтропию (Binary Cross-Entropy):

$$BCE(y_i, p_i) = -y_i \cdot \log_2 p_i + (1 - y_i) \log_2 (1 - p_i). \quad (6)$$

Функцией, определяющей выходное значение нейрона в зависимости от результата взвешенной суммы входов и порогового значения, является функция мягкого максимума (SoftMax). Она является обобщенной логистической функцией для многомерного случая и вычисляется следующим образом:

$$f(p_i) = \frac{e^{p_i}}{\sum_{i=1}^M e^{p_i}}. \quad (7)$$

3. Общая структура и реализация методики обнаружения аномалий и классификации КА в СПД.

Общая структура. Предлагаемая методика обнаружения аномалий и классификации КА в СПД включает пять этапов (рисунок 2):

- 1) сбор сетевого трафика;

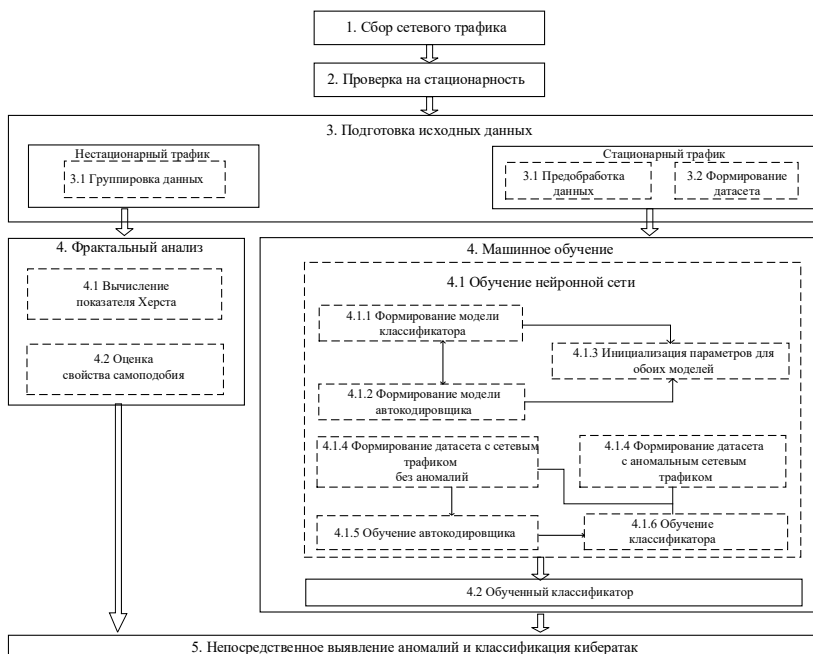


Рис. 2. Общая структура методики выявления аномалий и классификации КА в СПД

- 2) проверка трафика на стационарность;
- 3) подготовка исходных наборов данных;
- 4) фрактальный анализ и машинное обучение;
- 5) непосредственное выявление аномалий и классификация кибератак с помощью обученного классификатора.

После сбора сетевого трафика осуществляется его проверка на стационарность с использованием теста Дики-Фуллера. Подготовка исходных наборов данных (датасетов) необходима как для стационарного, так и для нестационарного случая. В нестационарном случае исходные наборы данных используются для вычисления показателя Херста методом DFA. Эти оценки используются на следующем этапе для выявления аномалий сетевого трафика путем сравнения текущего и предварительно рассчитанного эталонного показателей Херста.

В стационарном случае исходные наборы данных применяются для обучения автокодировщика, использующего LSTM-ячейки, и связанного с ним классификатора.

На заключительном этапе осуществляется целевая обработка трафика, заключающаяся в непосредственном выявлении аномалий по результатам фрактального анализа (для стационарного и нестационарного трафика) и классификации атак с помощью обученных автокодировщика и классификатора (для стационарного трафика).

Реализация. Для реализации разработанной методики обнаружения аномалий и классификации КА в СПД разработан программный прототип, схема работы которого представлена на рисунке 3.

Прототип разработан на языке Python. Выбор этого языка был обусловлен тем, что он ориентирован на повышение производительности разрабатываемого кода, поддерживает многопоточные вычисления и имеет большое количество библиотек. В частности, использовались библиотека универсального назначения Pandas и библиотека NumPy, позволяющий работать с многомерными массивами (тензорами) и математическими функциями. Для построения графиков применялся модуль Matplotlib. Необходимые расчеты проводились в интегрированной среде разработки Jupiter notebook.

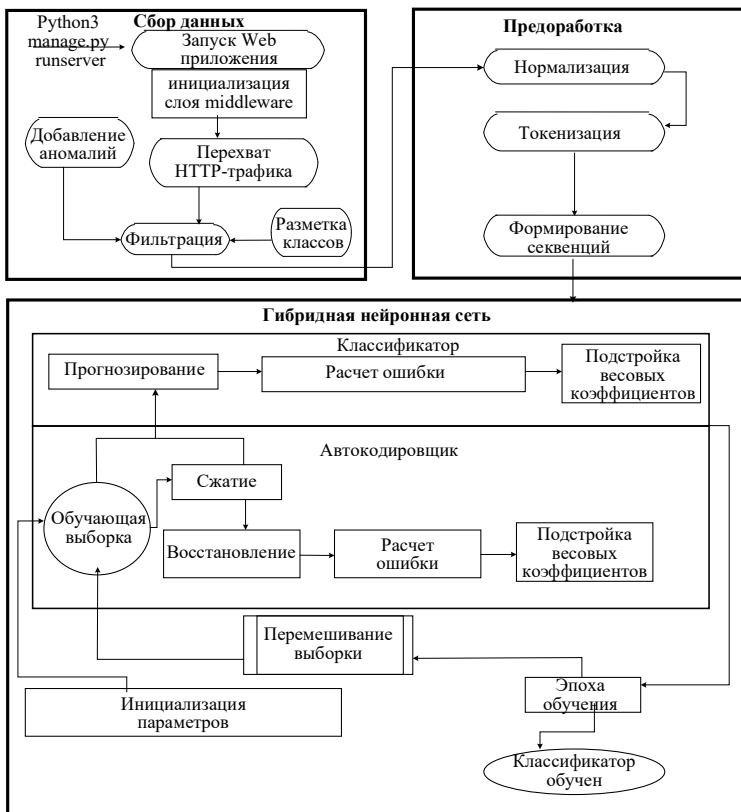


Рис. 3. Схема работы программного прототипа, реализующего методику

Программный прототип включает в себя 3 подсистемы:

- 1) сбора данных;
- 2) предобработки сформированного набора данных;
- 3) гибридная нейронная сеть.

Главной задачей первой подсистемы является сбор, обработка и анализ сформированного набора данных. Сбор данных, предназначенных для обучения нейронной сети, осуществлялся следующим образом. На языке Python было написано Web-приложение, способное перехватывать любые пользовательские запросы с помощью промежуточного программного слоя (middleware). Такой подход позволяет обрабатывать запросы из браузера прежде, чем они достигнут представления сервера Django, а также ответы от представлений до того, как они возвращаются в браузер.

Перехваченные запросы записываются в лог-файл (журнализируются). Для старта Web-приложения запускается HTTP-сервер с интерфейсом шлюза веб-сервера Python. Для этой цели вводится команда `python manage.py runserver`.

В набор данных, сформированный после сбора HTTP трафика, добавляются аномальные запросы для задания мультиклассовости КА. К такого рода запросам относятся: SQL Injection, Cross-Site Scripting, Cross-Site Request Forgery, XML External Entity Injection, CRLF Injection и HTTP Response Splitting. Каждый тип аномального запроса помечается в наборе данных как отдельный класс.

Главной задачей второй подсистемы является нормализация полученного набора данных. Для этого запросы оборачиваются специальными токенами <START> и <STOP>. Это позволяет задавать верное вероятностное распределение над последовательностями разной длины. С помощью теста Дики-Фуллера производится оценка стационарности получившегося ряда путем нахождения распределения длин между двумя одинаковыми символами.

После нормализации данные токенизируются. Поскольку HTTP является текстовым протоколом, для токенизации используется векторное представление символов. Для этой цели сперва осуществляется замена символов, встречающихся в наборе данных, на числовой эквивалент, который не имеет самостоятельного значения для внешнего или внутреннего использования. Затем слова переводятся в последовательность секвенций, т.е. пронумерованный набор объектов, среди которых допускаются повторения, причем порядок объектов имеет значение. Нумерация происходит натуральными числами

При этом учитывается то, что все секвенции должны быть одной длины. Если запрос меньше длины секвенции, то оставшиеся символы заполняются нулями.

Главной задачей третьей подсистемы является обучение нейронной сети и выявление аномалий в СПД. Для этого первоначально инициализируются гиперпараметры гибридной нейронной сети, и происходит ее обучение на сформированных секвенциях. Классификатор гибридной нейронной сети ищет закономерности в данных, привязывая их к размеченным классам на этапе обучения. Данные, которые классификатор не смог отнести к какому-либо классу, в том числе и к классу легитимных данных, помечаются как аномальные. Они соответствуют атакам «нулевого дня».

Анализ аномалий в стационарной сети. Для выявления аномалий в стационарной сети предлагается использовать гибридную нейронную сеть, модель которой показана на рисунке 4.

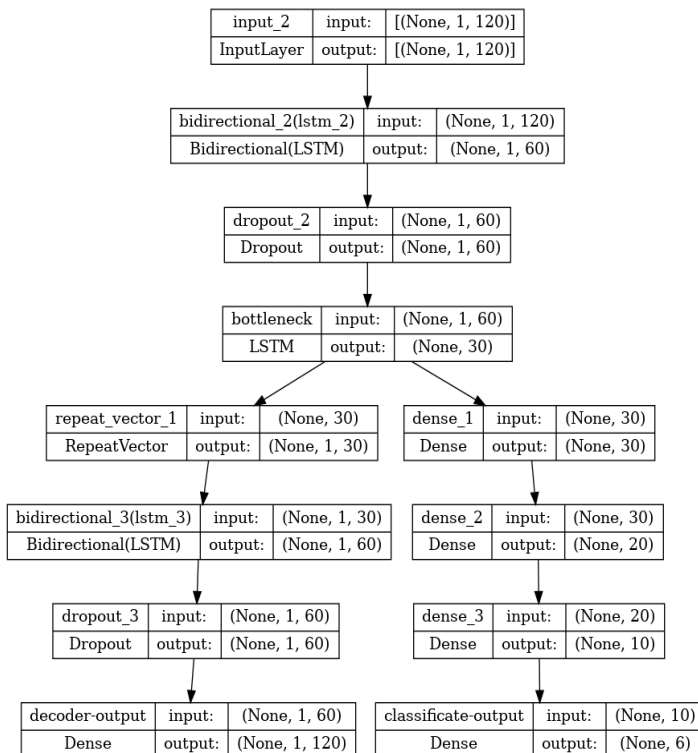


Рис. 4. Модель гибридной нейронной сети

Гибридная нейронная сеть имеет две ветви и соответствующие им два выхода.

Гибридная сеть имеет различные по своему назначению слои. Наиболее характерными слоями являются следующие:

- *Dropout* (отсеивать) – этот слой предназначен для решения проблемы переобучения в нейронных сетях;
- *Bidirectional* (двунаправленный) – это слой позволяет осуществлять генеративное глубокое обучение, при котором выходной слой может одновременно получать информацию из прошлого (назад) и будущего (вперед) состояний;

– *Bottleneck* (узкое место) – этот слой позволяет уменьшать количество свойств и, соответственно, количество операций в каждом слое, что обеспечивает высокую скорость получения результата.

Входной слой гибридной нейронной сети имеет 120 нейронов, применяющихся как для автокодировщика, так и для классификатора.

В качестве слоев автокодировщика используются ячейки LSTM [34]. Сети LSTM являются подтипом более общих рекуррентных нейронных сетей. Ключевым атрибутом таких нейронных сетей является их способность сохранять информацию (состояние ячейки) для ее дальнейшего использования. LSTM может удалять информацию из состояния ячейки. Этот процесс регулируется фильтрами. Они позволяют пропускать информацию на основании некоторых условий. Фильтры состоят из слоя сигмоидальной нейронной сети и операции поточечного умножения. Сигмоидальный слой возвращает числа от нуля до единицы, определяющие, какую долю каждого блока информации следует пропускать дальше по сети. Ноль в данном случае означает «не пропускать ничего», единица – «пропустить все».

Свойство рекуррентности позволяет искусственной нейронной сети «обращаться» к результатам своей работы в прошлом, делать анализ предсказаний. Тем самым контекст решений в будущем будет зависеть не только от первичного глубокого обучения LSTM, но и ее дальнейшей работы в потоке [37, 38].

В процессе обучения на входной слой гибридной нейронной сети поступают различные вектора (рисунок 5) (падасеквенции, секвенции или эмбединги) в зависимости от реализации. Различными оттенками серого цвета отражаются разные типы атак – SQL инъекции, несанкционированный доступ, несанкционированный доступ с кодированием, ХХЕ-инъекция и внедрение шаблонов на стороне сервера. Падасеквенция – это функция библиотеки Tensorflow, которая используется для того, чтобы все последовательности в списке имели одинаковую длину. По умолчанию это делается путем добавления нуля в начало каждой последовательности, пока каждая последовательность не будет иметь ту же длину, что и самая длинная последовательность. А для преобразования положительных целых чисел (индексов) в плотные векторы фиксированного размера применяется первый слой нейронной сети – эмбединг (Embedding). Эмбединги требуют больших вычислительных ресурсов. Поэтому для быстрых вычислений, как показали исследования, лучше применять падасеквенции длиной 120 символов.




Рис. 5. Визуальное представление векторного представления данных, подаваемых на вход гибридной нейронной сети

В середине гибридной нейронной сети число нейронов уменьшается до 30. Это приводит к потере информации, так как из 120 нейронов не вся информация попадает на 30 нейронов.

У классификатора (правая ветвь) на последнем слое имеется шесть нейронов, которые соответствуют шести размеченным классам, упомянутым выше. Если классификатор не может отнести данные ни к одному из классов с вероятностью больше 0,6, то такой запрос отмечается подозрительным (может считаться атакой нулевого дня). У автокодировщика на последнем слое имеется 120 нейронов. Он приводит информацию, содержащуюся на 30 нейронах, к первоначальному виду. В результате в середине слоя сохраняется только самая важная информация, из которой можно восстановить информацию в исходном виде – «скрытые латентные представления».

Пример отображения скрытых латентных представлений показан на рисунке 6. Такие представления позволяют классификатору находить дополнительные закономерности в данных. Это существенно уменьшает ложные срабатывания, что, в свою очередь, повышает вероятность обнаружения атак нулевого дня.




Рис. 6. Скрытые латентные представления, полученные в результате сжатия информации автокодировщиком

4. Экспериментальная оценка методики выявления аномалий и КА в СПД. Для экспериментальной оценки рассматриваемой методики разработан киберполигон, представленный на рисунке 7.

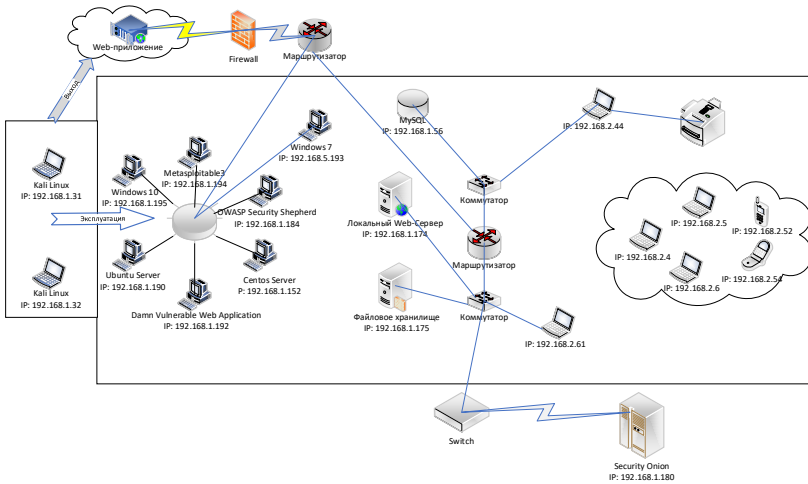


Рис. 7. Киберполигон для сбора и анализа защищенности сетевого трафика

На киберполигоне проведено около 30 видов кибератак и сгенерировано 40 Гб легитимного трафика. Сетевой трафик записывался в pcap-файлы. Из этого трафика формировался набор

данных с помощью Netsniff-ng и Bro. Атаки проводились с помощью дистрибутива Kali Linux на заведомо уязвимые сервисы, развернутые в центральной части схемы. Далее проводился поиск аномальных всплесков с помощью методов кумулятивных сумм, RF и SVM.

Несмотря на то, что эти алгоритмы прекрасно справляются с задачами поиска аномальных всплесков, было обнаружено, что не всегда всплески являются аномалиями. Для передачи пакетов данных рассматривались современные стандарты, протоколы и технологии построения высокоскоростных СПД. Сценарий, по которому происходила передача пакетов сообщений, в этом случае являлся стационарным. При этом предполагалось, что СПД обладает свойством самоподобия. Это предположение в дальнейшем было подтверждено в ходе экспериментов. Также предполагалось, что порты в оборудовании пограничной сети имеют пропускную способность 1 Гбит/с и работают по протоколу Ethernet [1].

Генерация трафика осуществлялась с помощью имитационной модели, разработанной в среде симулятора GNS3.

Перечень основных атрибутов, которые были включены в сгенерированный набор данных, представлены в таблице 1. Общее количество различных значений параметра Flow.ID в наборе данных оказалось равным 1522917. Анализ самоподобия проводился по временному ряду, образованному из значений поля Packet.Length.Mean. Этот атрибут в сгенерированном наборе данных имел 10700 уникальных значений. Наиболее часто встречались значения 267,5 и 243,5 [1].

На смоделированную сетевую инфраструктуру воздействовали два типа КА. Этими атаками были DDoS-атака и «Сканирование сети и ее уязвимостей» [39, 40]. Трафик под воздействием атаки первого типа моделировался с помощью тестового оборудования для IP-сетей IXIA. Для реализации кибератак первого типа использовались распределенная сеть и методы SYN Flood, Ping Flood и UDP Flood. Второй тип атаки моделировался с помощью средств сканирования IP-сетей Nmap и Xspider. Для реализации этой атаки использовался метод зондирования.

Анализ сетевого трафика в условиях воздействия указанных КА показал, что многие всплески являются легитимными. С другой стороны, во многих местах, где отсутствуют всплески, имеются аномалии. Поэтому необходимо эффективное обнаружение всплесков трафика, выделение из них аномальных, классификация выявленных аномалий с целью прогнозирования факта воздействия КА и выработки мероприятий по противодействию КА.

Таблица 1. Атрибуты сгенерированного набора данных

№	Имя атрибута	Комментарии
Атрибуты общего назначения		
1	Timestamp	Момент захвата пакета
2	Protocol	Идентификатор протокола транспортного уровня
3	Flow.ID	Идентификатор потока
4	Flow.Duration	Общая продолжительность потока
Атрибуты, характеризующие длину пакета в прямом направлении		
5	Fwd.Packet.Length.Max	Максимальная длина пакета в прямом направлении
6	Fwd.Packet.Length.Mean	Средняя длина пакета в прямом направлении
7	Fwd.Packet.Length.Min	Минимальная длина пакета в прямом направлении
8	Fwd.Packet.Length.SD	Стандартное отклонение длины пакета в прямом направлении
Атрибуты, характеризующие длину пакета в обратном направлении		
9	Bwd.Packet.Length.Max	Максимальная длина пакета в обратном направлении
10	Bwd.Packet.Length.Mean	Средняя длина пакета в обратном направлении
11	Bwd.Packet.Length.Min	Минимальная длина пакета в обратном направлении
12	Bwd.Packet.Length.SD	Стандартное отклонение длины пакета в обратном направлении
Атрибуты источника и получателя пакетов		
13	Source.IP	IP-адрес источника потока
14	Source.Port	Номер порта источника
15	Destination.IP	IP-адрес получателя
16	Destination.Port	Номер порта получателя
Атрибуты с обобщенными данными		
17	Packet.Length.Mean	Среднее значение длины пакетов, зарегистрированных в потоке в прямом и обратном направлениях
18	Total.Fwd.Packets	Общее количество прямых пакетов
19	Total.Backward.Packets	Общее количество обратных пакетов
20	Total.Length.of.Fwd	Общее количество байтов в прямом направлении, полученных от всего потока
21	Total.Length.of.Backward	Общее количество байтов в обратном направлении, полученное из всего потока

Сетевой трафик, полученный с применением кибернетического полигона, разделялся на легитимные и аномальные выборки. Для

каждой выборки вычислялся показатель Херста по алгоритмам R/S и DFA.

Пример вычисления H для нестационарного легитимного и аномального трафика UDP подробно описан в [1, 10].

Обучающий набор данных для идентификации и классификации атак включал как легитимный, так и аномальный трафик.

На вход автокодировщика подавался только легитимный трафик. На вход классификатора поступал легитимный и аномальный трафик, а также скрытые латентные представления, полученные от автокодировщика после кодирования информации. Подбор параметров осуществлялся таким образом, чтобы функция потерь при обучении автокодировщика уменьшалась, в то время как точность классификатора росла.

Для оценки точности и полноты обнаружения аномалий на обученной нейронной сети вначале использовался набор данных с кибератаками, применявшийся для обучения сети. Точность обнаружения аномалий в этом случае составила 96,9 %.

На рисунке 8 показано, как изменялись точность классификатора и функция потерь за 200 циклов (эпох) обучения. Точность классификатора (рисунок 8а) стремительно возрастает приблизительно на 15-ой эпохе обучения. На 200-ой эпохе она приближается к единице. В то же время функция потерь (рисунок 8б) уменьшается (особенно сильно – с 15-ой эпохи) и на 200-ой эпохе стремится к нулю.




Рис. 8. Зависимости точности (Accuracy) и потерь (Loss) от эпох обучения при обучении декодера и классификатора

Затем был сформирован новый набор данных, который включал атаки, ранее неизвестные классификатору (атаки нулевого дня). Было распознано 80% неизвестных ранее атак нулевого дня, и было верно определено, что 99% легитимных запросов не являются аномальными. Кроме того, было замечено, что возможны ложные срабатывания. В частности, было отброшено всего 2 запроса. Учитывая тот факт, что в наборе данных содержится 57000 запросов, из которых 20000 являются аномальными, можно сделать вывод, что данный факт не относится к существенным недостаткам рассматриваемой методики.

Помимо эксперимента по обнаружению аномалий был проведен эксперимент по классификации КА. Одним из методов оценки качества работы классификатора и выбора дискриминационного порога для разделения классов является ROC-кривая (кривая ошибок) (рисунок 9).

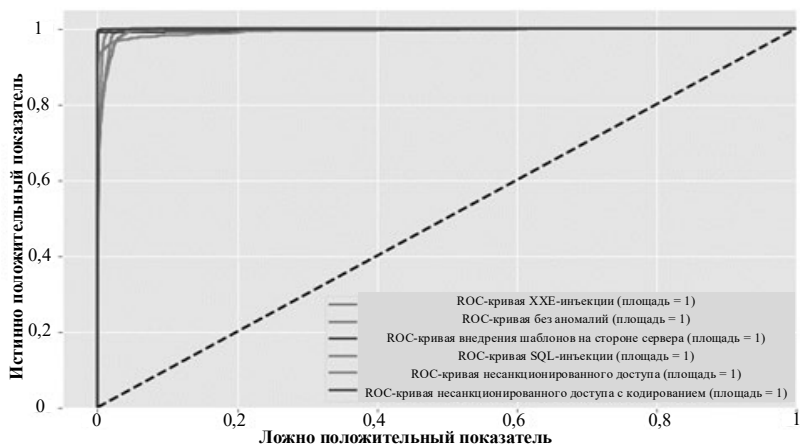


Рис. 9. ROC-кривая для мультиклассовой классификации

ROC-кривая описывает взаимосвязь между чувствительностью модели машинного обучения (true positives rate – доля истинно положительных примеров) и ее специфичностью (true negative rate – доля ложно положительных результатов).

Преимуществом ROC-кривой является ее инвариантность относительно отношения ошибки первого и второго рода. Оптимальное местонахождение точек ROC-кривой – в левом верхнем углу графика, где специфичность и чувствительность находятся на оптимальных уровнях. Именно такое положение ROC-кривой и было зафиксировано в проводимых экспериментах.

Площадь под ROC-кривой определяет точность классификации модели машинного обучения. Чем больше эта площадь, тем больше расхождение между истинными и ложными срабатываниями и тем выше эффективность процесса классификации. Иными словами, чем ближе площадь под ROC-кривой к единице, тем лучше. Практически для всех видов КА, учитываемый в экспериментах, площадь под ROC-кривой была приближенно равна единице.

Визуальный анализ подтвердил высокую точность предложенного подхода с минимальным числом ложных срабатываний. Для более качественной оценки были выделены основные показатели классификации атак (рисунок 10): точность (precision), полнота (recall) и F-мера (f1-score). F-мера является средним гармоническим между точностью и полнотой и играет роль комплексного показателя, позволяющего оценить эффективность классификации атак.

	precision	recall	f1-score	support
xhe	0.83	0.95	0.88	1292
no anomaly	0.99	1.00	0.99	9266
server side template injection	1.00	0.99	0.99	1265
sql injection	0.96	0.93	0.95	1271
traversal	0.94	0.80	0.86	1263
encoding traversal	0.99	0.99	0.99	1305
accuracy			0.97	15662
macro avg	0.95	0.94	0.94	15662
weighted avg	0.97	0.97	0.97	15662

Рис. 10. Основные показатели классификации атак

Из рисунка 10 видно, что для различных видов атак эффективность их классификации находилась в диапазоне от 0,88 (для ХХЕ-инъекции) до 0,99 (для атак внедрения шаблона на стороне сервера и несанкционированного доступа с кодированием).

При этом следует заметить, что разработанная методика не только имеет высокую эффективность классификации КА, но также имеет высокую эффективность обнаружения легитимных запросов (обозначено на рисунке как «no anomaly»), равную 0,99. Этот факт сам по себе говорит о минимизации ложных срабатываний (ошибок первого рода), связанных с отнесением легитимных запросов к атакам, и наоборот.

Сравнительная оценка предложенной методики с другими аналогичными методами и методиками показала, что в ней

обеспечивается достаточно высокая скорость обнаружения известных КА (рисунок 11).

Так, предложенной методике, как и сигнатурному методу, для обнаружения известных КА с вероятностью, превышающей 0,96, достаточно 5 секунд работы на компьютере стандартной конфигурации. В то же время статистическим методам и методам машинного обучения для этого требуется порядка 30 секунд. Это связано с тем, что статистические методы используют накопленную статистику, а эффективность методов машинного обучения зависит от используемых ими моделей классификации и кластеризации [41, 42]. В методах машинного обучения на этапе обучения используется обучающая выборка (train-выборка), а эффективность обнаружения КА оценивается и проверяется на основе тестовой выборки (test-выборки).




Рис. 11. Сравнительная оценка скорости обнаружения известных КА

Если проводить сравнительную оценку методов и методик по эффективности обнаружения неизвестных КА, то можно утверждать, что в этом случае разработанная методика не уступает по своей эффективности методам машинного обучения, которые в настоящее время демонстрируют в этой области наилучшие результаты по сравнению с сигнатурным и статистическими методами (рисунок 12). Так, за время своей работы, равное 5 секунд, предлагаемая методика и сигнатурный метод позволяют обнаружить неизвестные КА с вероятностями 0,8 и 0,5 соответственно.




Рис. 12. Сравнительная оценка точности обнаружения неизвестных КА

Статистические методы и методы машинного обучения требуют на решение этой задачи, как было указано выше, порядка 30 секунд. Однако точность обнаружения неизвестных атак с помощью статистических методов менее 0,5, а у методов машинного обучения она может превышать 0,8.

Следует отметить, что дополнительным преимуществом предложенной методики является реализованная в ней возможность обнаружения аномалий в трафике любого рода. Остальные известные методы хорошо работают только в случае стационарного движения.

К числу других достоинств этого подхода следует отнести нетребовательность к системным ресурсам. Кроме того, предложенный подход универсален за счет представления процессов в виде временных рядов. Тип протокола передачи информации, а также вид передаваемой информации (служебная информация, синхронизация, полезная информация) никак не влияют на время определения коэффициента Херста. Он инвариантен к типам деструктивных воздействий и не требует настройки или адаптации к обнаружению конкретных видов атак, в том числе ранее неизвестных.

При этом следует отметить, что увеличение количества обрабатываемых параметров заголовка протокола передачи данных (длина пакета, флаги и т.д.) приводит к увеличению времени вычислений.

5. Заключение. В статье предложена обладающая высокой оперативностью и точностью методика обнаружения аномалий и КА, в которой выявление аномалий в сетевом трафике производится путем

оценки его свойства самоподобия в реальном масштабе времени или близком к реальному, а обнаружение КА и их классификация осуществляются с применением гибридной нейронной сети, в основе построения которой базируются ячейки LSTM. Специфика предлагаемой методики заключается в том, что обнаружение КА выполняется с использованием автокодировщика, обученного на основе эталонных данных работы сети и обмена информацией в ней с учетом всех отклонений от штатного режима работы сети.

В проведенных экспериментах рассматриваемая методика продемонстрировала довольно высокую точность раннего обнаружения КА, достигнув значения 0,93 для известных атак и 0,8 для заранее неизвестных атак.

Дальнейшие исследования связаны с интеграцией программной системы, реализующей предлагаемую методику, с другими известными программными средствами защиты, а также способами обнаружения атак и их классификации, имеющимися в арсенале систем компьютерной безопасности.

Литература

1. Kotenko I., Saenko I., Lauta O., Kribel A. An approach to detecting cyber attacks against smart power grids based on the analysis of network traffic self-similarity // *Energies*. 2020. vol. 13. no. 19. pp. 5031.
2. Al-Jarrah M., Khalaf G., Amin S. PIN Authentication Using Multi-Model Anomaly Detection in Keystroke Dynamics // *Proceedings of the 2019 2nd International Conference on Signal Processing and Information Security (ICSPIS)*. 2019. pp. 1–4.
3. Ageev S., Kotenko I., Saenko I., Kopchak Y. Abnormal Traffic Detection in Networks of the Internet of Things Based on Fuzzy Logical Inference // *Proceedings of the IEEE International Conference on Soft Computing and Measurements (SCM)*. 2015. pp. 5–8.
4. Котенко Д.И., Котенко И.В., Саенко И.Б. Методы и средства моделирования атак в больших компьютерных сетях: состояние проблемы // *Труды СПИИРАН*. 2012. № 3 (22). С. 5–30.
5. Brezigar-Masten A., Masten I. CART-based selection of bankruptcy predictors for the logit model // *Expert Systems with Applications*. 2012. vol. 39. no. 11. pp. 10153–10159.
6. Ju X., Chen V.C.P., Rosenberger J.M., Liu F. Fast knot optimization for multivariate adaptive regression splines using hill climbing methods // *Expert Systems with Applications*. 2021. no. 171. p. 114565.
7. Ju X., Rosenberger J.M., Chen V.C.P., Liu F. Global optimization on non-convex two-way interaction truncated linear multivariate adaptive regression splines using mixed integer quadratic programming // *Information Sciences*. 2022. no. 597. pp. 38–52.
8. Ju X., Liu F., Wang Li., Lee W.-J. Wind farm layout optimization based on support vector regression guided genetic algorithm with consideration of participation among landowners // *Energy Conversion and Management*. 2019. no. 196. pp. 1267–1281.

9. Dang T.D., Sonkoly B., Molnar S. Fractal analysis and modeling of VoIP traffic // Proceedings of the 11th International Telecommunications Network Strategy and Planning Symposium (NETWORKS 2004). 2004. pp. 123–130.
10. Leland W.E., Taqqu M.S., Willinger W., Wilson D.V. On the self-similar nature of Ethernet traffic // SIGCOMM Comput. Commun. 1993. vol. 23. no. 4. pp. 183–193.
11. Raimundo M.S., Okamoto Jr. J. Application of Hurst Exponent (H) and the R/S Analysis in the Classification of FOREX Securities // International Journal of Modeling and Optimization. 2018. no. 8. pp. 116–124.
12. Sánchez-Granero M.J., Fernández-Martínez M., Trinidad-Segovia J.E. Introducing fractal dimension algorithms to calculate the Hurst exponent of financial time series // Eur. Phys. J. B. 2012. vol. 85. no. 86.
13. 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. no. 18. p. 5963.
14. Kotenko I., Saenko I., Lautu O., Kribel A. Ensuring the survivability of embedded computer networks based on early detection of cyber attacks by integrating fractal analysis and statistical methods // Microprocessors and Microsystems. 2022. no. 90. p. 104459.
15. Strelkovskaya I., Solovskaya I., Makoganiuk A. Spline-Extrapolation Method in Traffic Forecasting in 5G Networks // Journal of Telecommunications and Information Technology. 2019. no. 3. pp. 8–16.
16. Carvalho P., Abdalla H., Soares A., Solis P., Tarchetti P. Analysis of the influence of self-similar traffic in the performance of real time applications. URL: citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.599.4041&rep=rep1&type=pdf (дата доступа: 15.07.2022).
17. Fractal Objects and Self-Similar Processes. URL: archive.physionet.org/tutorials/fmnc/node3.html (дата доступа: 15.07.2022).
18. Ruoyu Y., Wang Y. Hurst Parameter for Security Evaluation of LAN Traffic // Information Technology Journal. 2012. no. 11. pp. 269–275.
19. Singh Gulshan M.B., Sharma B., Grover M., Gupta P. TSA: Self-Train Self-Test Algorithm // Proceedings of the 2020 IEEE International Conference for Innovation in Technology (INOCON). 2020. pp. 1–5.
20. Yu Z., Jiang Z., Tan L., Liu H., Yang Q. Rescaled Range Analysis of Vessel Traffic Flow in the Yangtze River // Proceedings of the 2019 5th International Conference on Transportation Information and Safety (ICTIS). 2019. pp. 1–4.
21. Winter P., Lampesberger H., Zeilinger M., Hermann E. On Detecting Abrupt Changes in Network Entropy Time Series // Communications and Multimedia Security. CMS 2011. Lecture Notes in Computer Science. 2011. vol. 7025. pp. 194–205.
22. Sharma S., Sahu S.K., Jena S.K. On Selection of Attributes for Entropy Based Detection of DDoS // Proceedings of the 2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI). 2015. pp. 1096–1100.
23. Bhuyan M.H., Bhattacharyya D.K., Kalita J.K. Information metrics for low-rate DDoS attack detection: A comparative evaluation // Proceedings of the 2014 Seventh International Conference on Contemporary Computing (IC3). 2014. pp. 80–84.
24. Brauckhoff D., Wagner A., May M. FLAME: A Flow-Level Anomaly Modeling Engine // Proceedings of the Workshop on Cyber Security and Test. 2008. pp. 1–6.
25. Zhang S.T., Lin X.B., Wu L., Song Y.Q., Liao N.D., Liang Z.H. Network Traffic Anomaly Detection Based on ML-ESN for Power Metering System // Mathematical Problems in Engineering. 2020. vol. 2020. article ID 7219659.
26. Radford B.J., Apolonio L.M., Trias A.J., Simpson J.A. Network Traffic Anomaly Detection Using Recurrent Neural Networks. URL: doi.org/10.48550/arXiv.1803.10769 (дата доступа: 15.07.2022).

27. Браницкий А.А., Котенко И.В. Анализ и классификация методов обнаружения сетевых атак // Труды СПИИРАН. 2016. № 2 (45). С. 207–244.
28. Браницкий А.А., Котенко И.В. Обнаружение сетевых атак на основе комплексирования нейронных, иммунных и нейро-нечетких классификаторов // Информационно-управляющие системы. 2015. № 4 (77). С. 69–77.
29. Shaukat K., Luo S., Varadharajan V., Hameed I.A., Xu M. A Survey on Machine Learning Techniques for Cyber Security in the Last Decade // IEEE Access. 2020. vol. 8. pp. 222310–222354.
30. Chen W.-H., Hsu S.-H., Shen H.-P. Application of SVM and ANN for intrusion detection // Computers & Operations Research. 2005. vol. 32. no. 10. pp. 2617–2634.
31. Hasan M.A.M., Nasser M., Ahmad S., Molla K.I. Feature selection for intrusion detection using random forest // Journal of information security. 2016. vol. 7. no. 03. p. 129.
32. Zhang Y., Wang S., Wu L. Spam detection via feature selection and decision tree // Advanced Science Letters. 2012. vol. 5. no. 2. pp. 726–730.
33. Su M.-Y. Real-time anomaly detection systems for Denial-of-Service attacks by weighted k-nearest-neighbor classifiers // Expert Systems with Applications. 2011. vol. 38. no. 4. pp. 3492–3498.
34. Gers F., Schraudolph N., Schmidhuber J. Learning precise timing with LSTM recurrent networks // Journal of Machine Learning Research. 2002. vol. 3. pp. 115–143.
35. Shaukat S., Ali A., Batool A., Alqahtan, F., Khan J.S., Ahmad A.J. Intrusion Detection and Attack Classification Leveraging Machine Learning Technique // Proceedings of the 2020 14th International Conference on Innovations in Information Technology (IIT). 2020. pp. 198–202.
36. Nurul A.H., Zaheera Z.A., Puvanasvaran A.P., Zakaria N.A., Ahmad R. Risk assessment method for insider threats in cyber security: A review // International Journal of Advanced Computer Science and Applications (ijacsa). 2018. vol. 9. no. 11. pp.16–19.
37. Zhe W.; Wei C., Chunlin L. DoS attack detection model of smart grid based on machine learning method // Proceedings of the 2020 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS). 2020. pp. 735–738.
38. Karataş G., Akbulut A. Survey on Access Control Mechanisms in Cloud Computing // Journal of Cyber Security and Mobility. 2018. vol. 7. no. 3. pp. 1–36.
39. Lopez J., Rubio J. Access control for cyber-physical systems interconnected to the cloud // Comput. Netw. 2018. vol. 134. no. C. pp. 46–54.
40. Clincy V., Shahriar H. Web Application Firewall: Network Security Models and Configuration // Proceedings of the 2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC). 2018, pp. 835–836.
41. Visoottiviseth V., Sakarin P., Thongwilai J., Choobanjong T. Signature-based and behavior-based attack detection with machine learning for home IoT devices // Proceedings of the 2020 IEEE Region 10 conference (TEN-CON). 2020. pp. 829-834.
42. Amma N.G.B., Selvakumar S., Velusamy R.L. A Statistical Approach for Detection of Denial of Service Attacks in Computer Networks // IEEE Transactions on Network and Service Management. 2020. vol. 17. no. 4. pp. 2511–2522.

Котенко Игорь Витальевич — д-р техн. наук, профессор, заведующий лабораторией, лаборатория проблем компьютерной безопасности, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН); Санкт-Петербургский национальный исследовательский университет информационных технологий, механики и оптики (Университет ИТМО). Область научных интересов: безопасность компьютерных сетей, управление политиками безопасности,

разграничение доступа, аутентификация, анализ защищенности, обнаружение компьютерных атак, межсетевые экраны, защита от вирусов и сетевых червей, анализ и верификация протоколов безопасности и систем защиты информации, защита программного обеспечения от взлома и управление цифровыми правами, технологии моделирования и визуализации для противодействия кибертерроризму. Число научных публикаций — 1000. ivkote@comsec.spb.ru; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-7181.

Саенко Игорь Борисович — д-р техн. наук, профессор, ведущий научный сотрудник, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: автоматизированные информационные системы, информационная безопасность, обработка и передача данных по каналам связи, теория моделирования и математическая статистика, теория информации. Число научных публикаций — 400. ibsaen@comsec.spb.ru; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-7181.

Лаута Олег Сергеевич — д-р техн. наук, профессор кафедры, кафедра комплексного обеспечения информационной безопасности, Государственный университет морского и речного флота имени адмирала С.О. Макарова. Область научных интересов: защита от компьютерных атак. Число научных публикаций — 184. laos-82@yandex.ru; улица Двинская, 5/7, 198035, Санкт-Петербург, Россия; р.т.: +7(911)842-0228.

Крибель Александр Михайлович — научный сотрудник, лаборатория проблем компьютерной безопасности, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: защита от компьютерных атак. Число научных публикаций — 30. nemo4ka74@gmail.com; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-7181.

Поддержка исследований. Работа выполнена при частичной финансовой поддержке бюджетной темы FFZF-2022-0007.

I. KOTENKO, I. SAENKO, O. LAUTA, A. KRIEBEL
**ANOMALY AND CYBER ATTACK DETECTION TECHNIQUE
BASED ON THE INTEGRATION OF FRACTAL ANALYSIS AND
MACHINE LEARNING METHODS**

Kotenko I., Saenko I., Laut O., Kriebel A. Anomaly and Cyber Attack Detection Technique Based on the Integration of Fractal Analysis and Machine Learning Methods.

Abstract. In modern data transmission networks, in order to constantly monitor network traffic and detect abnormal activity in it, as well as identify and classify cyber attacks, it is necessary to take into account a large number of factors and parameters, including possible network routes, data delay times, packet losses and new traffic properties that differ from normal. All this is an incentive to search for new methods and techniques for detecting cyber attacks and protecting data networks from them. The article discusses a technique for detecting anomalies and cyberattacks, designed for use in modern data networks, which is based on the integration of fractal analysis and machine learning methods. The technique is focused on real-time or near-real-time execution and includes several steps: (1) detecting anomalies in network traffic, (2) identifying cyber attacks in anomalies, and (3) classifying cyber attacks. The first stage is implemented using fractal analysis methods (evaluating the self-similarity of network traffic), the second and third stages are implemented using machine learning methods that use cells of recurrent neural networks with a long short-term memory. The issues of software implementation of the proposed technique are considered, including the formation of a data set containing network packets circulating in the data transmission network. The results of an experimental evaluation of the proposed technique, obtained using the generated data set, are presented. The results of the experiments showed a rather high efficiency of the proposed technique and the solutions developed for it, which allow early detection of both known and unknown cyber attacks.

Keywords: cyber attack, fractal analysis, Hurst exponent, machine learning, LSTM.

References

1. Kotenko I., Saenko I., Laut O., Kriebel A. An approach to detecting cyber attacks against smart power grids based on the analysis of network traffic self-similarity. *Energies*. 2020. vol. 13. no. 19. p. 5031.
2. Al-Jarrah M., Khalaf G., Amin S. PIN Authentication Using Multi-Model Anomaly Detection in Keystroke Dynamics. *Proceedings of the 2019 2nd International Conference on Signal Processing and Information Security*. 2019. pp. 1-4.
3. Ageev S., Kotenko I., Saenko I., Kopchak Y. Abnormal Traffic Detection in Networks of the Internet of Things Based on Fuzzy Logical Inference. *Proceedings of the IEEE International Conference on Soft Computing and Measurements (SCM)*. 2015. pp. 5–8.
4. Kotenko D.I., Kotenko I.V., Saenko I.B. Methods and tools for modeling attacks in large computer networks: the state of the problem. *Trudy SPIIRAN – SPIIRAS Proceedings*. 2012. no. 3 (22). pp. 5–30. (In Russ.).
5. Brezigar-Masten A., Masten I. CART-based selection of bankruptcy predictors for the logit model. *Expert Systems with Applications*. 2012. vol. 39. no. 11. pp. 10153-10159.
6. Ju X., Chen V.C.P.; Rosenberger J.M., Liu F. Fast knot optimization for multivariate adaptive regression splines using hill climbing methods. *Expert Systems with Applications*. 2021. no. 171. p. 114565.

7. Ju X., Rosenberger J.M., Chen V.C.P., Liu F. Global optimization on non-convex two-way interaction truncated linear multivariate adaptive regression splines using mixed integer quadratic programming. *Information Sciences*. 2022. no. 597. pp. 38–52.
8. Ju X., Liu F., Wang Li., Lee W.-J. Wind farm layout optimization based on support vector regression guided genetic algorithm with consideration of participation among landowners. *Energy Conversion and Management*. 2019. no. 196. pp. 1267–1281.
9. Dang T.D., Sonkoly B., Molnar S. Fractal analysis and modeling of VoIP traffic. *Proceedings of the 11th International Telecommunications Network Strategy and Planning Symposium (NETWORKS 2004)*. 2004. pp. 123–130.
10. Leland W.E., Taqqu M.S., Willinger W., Wilson D.V. On the self-similar nature of Ethernet traffic. *SIGCOMM Comput. Commun.* 1993. vol. 23. no. 4. pp. 183–193.
11. Raimundo M.S., Okamoto Jr. J. Application of Hurst Exponent (H) and the R/S Analysis in the Classification of FOREX Securities. *International Journal of Modeling and Optimization*. 2018. no. 8. pp. 116–124.
12. Sánchez-Granero M.J., Fernández-Martínez M., Trinidad-Segovia J.E. Introducing fractal dimension algorithms to calculate the Hurst exponent of financial time series. *Eur. Phys. J. B*. 2012. vol. 85. no. 86.
13. Kotenko I., Saenko I., Laut O., Karpov M. Methodology for management of the protection system of smart power supply networks in the context of cyberattacks. *Energies*. 2021. vol. 14. no. 18. p. 5963.
14. Kotenko I., Saenko I., Laut O., Kribel A. Ensuring the survivability of embedded computer networks based on early detection of cyber attacks by integrating fractal analysis and statistical methods. *Microprocessors and Microsystems*. 2022. no. 90. p. 104459.
15. Strelkovskaya I., Solovskaya I., Makoganiuk A. Spline-Extrapolation Method in Traffic Forecasting in 5G Networks. *Journal of Telecommunications and Information Technology*. 2019. no. 3. pp. 8–16.
16. Carvalho P., Abdalla H., Soares A., Solis P., Tarchetti P. Analysis of the influence of self-similar traffic in the performance of real time applications. Available at: citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.599.4041&rep=rep1&type=pdf (accessed: 15.07.2022).
17. Fractal Objects and Self-Similar Processes. Available at: archive.physionet.org/tutorials/fmnc/node3.html (accessed: 15.07.2022).
18. Ruoyu Y., Wang Y. Hurst Parameter for Security Evaluation of LAN Traffic. *Information Technology Journal*. 2012. no. 11. pp. 269–275.
19. Singh Gulshan M.B., Sharma B., Grover M., Gupta P. TSA: Self-Train Self-Test Algorithm. *Proceedings of the 2020 IEEE International Conference for Innovation in Technology (INOCON)*. 2020. pp. 1–5.
20. Yu Z., Jiang Z., Tan L., Liu H., Yang Q. Rescaled Range Analysis of Vessel Traffic Flow in the Yangtze River. *Proceedings of the 2019 5th International Conference on Transportation Information and Safety (ICTIS)*. 2019. pp. 1–4.
21. Winter P., Lampesberger H., Zeilinger M., Hermann E. On Detecting Abrupt Changes in Network Entropy Time Series. *Communications and Multimedia Security. CMS 2011. Lecture Notes in Computer Science*. vol 7025. 2011. pp. 194–205.
22. Sharma S., Sahu S.K., Jena S.K. On Selection of Attributes for Entropy Based Detection of DDoS. *Proceedings of the 2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. 2015. pp. 1096–1100.
23. Bhuyan M.H., Bhattacharyya D.K., Kalita J.K. Information metrics for low-rate DDoS attack detection: A comparative evaluation. *Proceedings of the 2014 Seventh International Conference on Contemporary Computing (IC3)*. 2014. pp. 80–84.

24. Brauckhoff D., Wagner A., May M. FLAME: A Flow-Level Anomaly Modeling Engineo Proceedings of the Workshop on Cyber Security and Test. 2008. pp. 1–6.
25. Zhang S.T., Lin X.B., Wu L., Song Y.Q., Liao N.D., Liang Z.H. Network Traffic Anomaly Detection Based on ML-ESN for Power Metering System. *Mathematical Problems in Engineering*. 2020. vol. 2020. article ID 7219659.
26. Radford B.J., Apolonio L.M., Trias A.J., Simpson J.A. Network Traffic Anomaly Detection Using Recurrent Neural Networks. Available at: doi.org/10.48550/arXiv.1803.10769 (accessed: 15.07.2022).
27. Branitskiy A.A., Kotenko I.V. Analysis and classification of methods for network attack detection. *Trudy SPIIRAN – SPIIRAS Proceedings*. 2016. no. 2 (45). pp. 207–244. (In Russ.).
28. Branitskiy A.A., Kotenko I.V. Network Attack Detection Based on Combination of Neural, Immune and Neuro-fuzzy Classifiers. *Informacionno-upravlyayushchie sistemy – Information and Control Systems*. 2015. no. 4, pp. 152–159. (In Russ.).
29. Shaukat K., Luo S., Varadharajan V., Hameed I.A., Xu M. A Survey on Machine Learning Techniques for Cyber Security in the Last Decade. *IEEE Access*. 2020. vol. 8. pp. 222310-222354.
30. Chen W.-H., Hsu S.-H., Shen H.-P. Application of SVM and ANN for intrusion detection. *Computers & Operations Research*. 2005. vol. 32. no. 10. pp. 2617-2634.
31. Hasan M.A.M., Nasser M., Ahmad S., Molla K.I. Feature selection for intrusion detection using random forest. *Journal of information security*. 2016. vol. 7. no. 03. p. 129.
32. Zhang Y., Wang S., Wu L. Spam detection via feature selection and decision tree. *Advanced Science Letters*. 2012. vol. 5. no. 2. pp. 726-730.
33. Su M.-Y. Real-time anomaly detection systems for Denial-of-Service attacks by weighted k-nearest-neighbor classifiers. *Expert Systems with Applications*. 2011. vol. 38. no. 4. pp. 3492-3498.
34. Gers F., Schraudolph N., Schmidhuber J. Learning precise timing with LSTM recurrent networks. *Journal of Machine Learning Research*. 2002. vol. 3. pp. 115-143.
35. Shaukat S., Ali A., Batool A., Alqahtan, F., Khan J.S., Ahmad A.J. Intrusion Detection and Attack Classification Leveraging Machine Learning Technique. *Proceedings of the 2020 14th International Conference on Innovations in Information Technology (IIT)*. 2020. pp. 198–202.
36. Nurul A.H., Zahaera Z.A., Puvanasvaran A.P., Zakaria N.A., Ahmad R. Risk assessment method for insider threats in cyber security: A review. *International Journal of Advanced Computer Science and Applications (ijacsa)*. 2018. vol. 9. no. 11. pp. 16-19.
37. Zhe W.; Wei C., Chunlin L. DoS attack detection model of smart grid based on machine learning method. *Proceedings of the 2020 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS)*. 2020. pp. 735–738.
38. Karataş G., Akbulut A. Survey on Access Control Mechanisms in Cloud Computing. *Journal of Cyber Security and Mobility*. 2018. vol. 7. no. 3. pp. 1-36.
39. Lopez J., Rubio J. Access control for cyber-physical systems interconnected to the cloud. *Comput. Netw*. 2018. vol. 134. no. C. pp. 46-54.
40. Clincy V., Shahriar H. Web Application Firewall: Network Security Models and Configuration. *Proceedings of the 2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)*. 2018. pp. 835–836.
41. Visoottiviseth V., Sakarin P., Thongwilai J. Choobanjong T. Signature-based and behavior-based attack detection with machine learning for home IoT devices. *Proceedings of the 2020 IEEE Region 10 conference (TEN-CON)*. 2020. pp. 829-834.

42. Amma N.G.B., Selvakumar S., Velusamy R.L. A Statistical Approach for Detection of Denial of Service Attacks in Computer Networks. 2020. vol. 17. no. 4. pp. 2511-2522.

Kotenko Igor — Ph.D., Dr.Sci., Professor, Head of laboratory, Laboratory of computer security problems, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS); Saint Petersburg National Research University of Information Technologies, Mechanics and Optics (ITMO University). Research interests: computer network security, security policy management, access control, authentication, network security analysis, intrusion detection, firewalls, deception systems, malware protection, verification of security systems, digital right management, modeling, simulation and visualization technologies for counteraction to cyber terrorism. The number of publications — 1000. ivkote@comsec.spb.ru; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-7181.

Saenko Igor — Ph.D., Dr.Sci., Professor, Leading researcher, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: automated information systems, information security, processing and data transfer on data links, theory of modeling and mathematical statistics, information theory. The number of publications — 400. ibsaen@comsec.spb.ru; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-7181.

Lauta Oleg — Ph.D., Dr.Sci., Professor of the department, Department of integrated information security, State University of the Sea and River Fleet named after Admiral S.O. Makarov. Research interests: protection from computer attacks. The number of publications — 184. laos-82@yandex.ru; 5/7, Dvinskaya St., 198035, St. Petersburg, Russia; office phone: +7(911)842-0228.

Kriebel Alexander — Researcher, laboratory of computer security problems, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: protection against computer attacks. The number of publications — 30. nemo4ka74@gmail.com; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-7181.

Acknowledgements. The reported study was partially funded by the budget project FFZF-2022-0007.

Д.С. ДУДАКОВА, В.М. АНОХИН, М.О. ДУДАКОВ, А.Л. РОНЖИН
**О ТЕОРЕТИЧЕСКИХ ОСНОВАХ АЭРОЛИМНОЛОГИИ:
ИЗУЧЕНИЕ ПРЕСНЫХ ВОДОЕМОВ И ПРИБРЕЖНЫХ
ТЕРРИТОРИЙ С ПРИМЕНЕНИЕМ ВОЗДУШНЫХ
РОБОТОТЕХНИЧЕСКИХ СРЕДСТВ**

Дудакова Д.С., Анохин В.М., Дудаков М.О., Ронжин А.Л. О теоретических основах аэролимнологии: изучение пресных водоемов и прибрежных территорий с применением воздушных робототехнических средств.

Аннотация. Интеграция методологического базиса нескольких разных наук при междисциплинарных исследованиях является характерной чертой новых механизмов решения современных прикладных задач. Формируемые теоретические основы аэролимнологии, как нового научного направления, рассматриваются с точки зрения вклада в нее трех ключевых наук: лимнологии, информатики и робототехники. Приведены классификации методов и способов лимнологических исследований, воздушных робототехнических средств, информационных технологий, перспективных для решения задач в области аэролимнологии. Задача научного направления аэролимнологии формулируется как изучение возможностей и ограничений комбинированных способов дистанционного сенсорного измерения, роботизированного пробоотбора и аналитического исследования параметров экосистем пресных водоемов для мониторинга и предсказания динамики их развития. Среди основных направлений аэролимнологических исследований выделены: построение ортофотопланов и фотограмметрических пространственных моделей рельефа дна и отдельных элементов донного ландшафта и прибрежной зоны разного масштаба; геолого-геофизическое картирование подводной части береговой зоны; изучение фитопланктона, в частности «цветения» воды, вызванного цианобактериями; исследование распределения и миграций крупных представителей гидрофауны; изучение температурных полей и процессов перераспределения водных масс. Обсуждаются ограничения, накладываемые на использование беспилотных летательных аппаратов (БПЛА) при пробоотборе и мониторинге прибрежных водных территорий, прежде всего погодно-климатические, временные, пространственные, технические. Преимущество использования беспилотных летательных аппаратов в аэролимнологии обосновывается увеличением скорости получения данных, возможностью полета к труднодоступным и территориально удаленным объектам, снижением влияния человеческого фактора. Научная новизна представленного исследования состоит в попытке интеграции междисциплинарных знаний при использовании беспилотных летательных аппаратов и обработке полученных данных на основе технологий искусственного интеллекта при изучении лимнологических объектов и процессов. Отмечается важная роль геоинформационных систем и приводятся примеры карт типизации берегов и геоморфологии Ладожского озера, размещенные на сайте Центра коллективного пользования научным оборудованием «Северо-Западный центр мониторинга и прогнозирования развития территорий» СПб ФИЦ РАН. Рассматриваются основные этапы методологии проведения аэролимнологических исследований с применением междисциплинарных подходов на основе лимнологии, информатики и робототехнических средств, функционирующих в разных средах.

Ключевые слова: аэролимнология, озероведение, беспилотные летательные аппараты, пресные водоемы, Ладожское озеро, пробоотбор, мониторинг, информатика, робототехника, ГИС.

1. Введение. Междисциплинарные исследования характеризуются эмерджентным использованием подходов и средств одновременно нескольких наук с целью повышения качества измерительных, аналитических этапов изучения и разработки новых оригинальных методов и моделей [1, 2]. Развиваемые теоретические основы аэролимнологии формируются как минимум на трех ключевых науках: лимнологии, информатике и робототехнике.

Целью исследования, результаты которого приведены в данной статье, являлось введение научно-обоснованного нового понятия «аэролимнология», расширяющего технологические основы изучения пресных водоемов и прибрежных территорий с применением воздушных робототехнических средств. Вербально формальная постановка задачи может быть изложена следующим образом. Пусть имеются лимнологические объекты и процессы, требующие исследований в определенных условиях пространственно-временных ограничений, необходимо сформировать методологию проведения аэролимнологических исследований, определяющую требования к беспилотным летательным аппаратам, осуществляющим аэросъемку и физическое взаимодействие со средой на изучаемой территории, и к аналитическому и информационному обеспечению обработки проб, данных и знаний, используемых при визуализации результатов и прогнозирования развития лимнологических объектов.

С точки зрения дериватологии понятие аэролимнология сформировано путем сложения трех производящих основ: аэро, лимно, логия. Если рассматривать диахроническое словообразование термина, то изначально появилась наука лимнология, изучающая водоемы. Добавление основы аэро направлено на сигнификацию применения воздушных измерительных средств в изучении лимнологических процессов. При этом не следует трактовать аэролимнологию, как научное направление изучающее воздушную среду.

На рисунке 1 представлена структура используемых методов, технологий и средств для решения междисциплинарных задач аэролимнологии. В разрабатываемом направлении лимнология, сформированная на стыке геологии, физики, химии и биологии, изучает физические, химические и биологические свойства пресных водоёмов с применением дистанционных измерительных средств. Информатика предоставляет технологии искусственного интеллекта, машинного обучения, визуализации данных и представления знаний. Робототехника, включая беспилотные летательные аппараты и методы их управления, применяется для дистанционного измерения

надводных и подводных характеристик водоемов и прибрежных территорий.

Аэролимнология изучает возможности и ограничения комбинированных способов дистанционного сенсорного измерения, роботизированного пробоотбора и аналитического исследования параметров экосистем пресных водоемов для мониторинга и предсказания динамики их развития.



Рис. 1. Междисциплинарные направления исследований аэролимнологии и привлекаемые методы и средства других наук

История развития подходов и дистанционных средств, применяемых в аэрофотогеодезических исследованиях водных объектов-суши, начинается с конца 19 века, когда воздушные шары применялись для аналоговой фотосъемки [3]. При этом значительная нагрузка на техническую и интеллектуальную обработку изображений ложилась на персонал. Снимков было не много, и они изучались тщательным образом с извлечением различных экспертных наблюдений и знаний. Например, наличие брода, а, следовательно, небольшие глубины и скорость течения, пологие склоны берегов, выявлялись по присутствию наезженных дорог с обоих берегов рек [3]. С развитием робототехники и технологий искусственного интеллекта

лимнология получила значительное развитие за счет внедрения дистанционных информационно-измерительных сенсорных систем и методов обработки данных и знаний.

Также следует упомянуть аэрологию, как раздел метеорологии, изучающий процессы, протекающие в атмосфере, и как отрасль горной науки, связанная с анализом движения воздуха, переноса газообразных примесей и тепла в горных шахтах [4]. Аэрология также применяет воздушные средства измерения, в том числе зонды аэростатного, самолетного, ракетного типа, но исключительно для анализа параметров воздушных масс. В задачи же аэролимнологии входит изучение наземных объектов и процессов с помощью воздушных средств.


Под перспективными аэролимнологическими средствами анализа и мониторинга понимаются беспилотные летательные аппараты (БПЛА), оснащенные оптическими, оптоэлектронными, электромагнитными сенсорными системами, обеспечивающие регистрацию данных, предварительную обработку бортовыми вычислителями и беспроводную передачу полученной информации на стационарно размещенную геоинформационную систему, накапливающую и обрабатывающую потоки данных, информации и знаний с гетерогенных источников.

Особый интерес и новые возможности в связи с привлечением БПЛА появляются для построения ортофотопланов и фотограмметрических пространственных моделей рельефа прибрежной зоны, береговой линии, береговых процессов, прибрежных подводных ландшафтов [5–7]. На рисунках 2 и 3 приведены примеры снимков с высоким разрешением, сделанных видеокамерой с БПЛА, для решения различных задач лимнологии. При этом в большинстве случаев последующее оценивание изучаемого объекта производится только экспертным путем без привлечения технологий искусственного интеллекта и сторонних пространственно-временных данных, что существенно ограничивает проводимые исследования.

Оптико-магнитное навесное оборудование на БПЛА позволяет осуществлять геолого-геофизические исследования акваторий в удаленных или труднодоступных местах [8, 9].

Следующим важным направлением исследований аэролимнологии является изучение растительных сообществ – формирование карт мелководных зарастаний высшей водной растительностью [10], а также изучение фитопланктона [11–13]. Для последнего проводится исследование характеристик поверхностного

слоя водного зеркала водоемов, среди которых важнейшим параметром является концентрация хлорофилла – индикатора развития водорослей – краеугольного камня первичной продукции водоемов, определяющего общую продуктивность гидроэкосистемы. Чрезмерное развитие некоторых видов водорослей (в первую очередь синезеленых водорослей, или цианобактерий), проявляющееся в виде «цветения», может приводить к негативным последствиям для водоемов.



Изучение подводных элементов рельефа прибрежной зоны и оценка межгодовых изменений уровня воды



Геологические исследования, изучение характера трещиноватости пород




Мониторинг изменений антропогенно измененного залива



Изучение влияния притоков



Изучение береговой зоны и береговых процессов



Изучение береговых процессов и влияния притоков

Рис. 2. Примеры аэрофотоснимков для решения задач аэролимнологии (геолого-геофизический анализ прибрежной зоны; изучение процессов перераспределения водных масс)



Изучение типов берегов шхерного района и оценка развития водных макрофитов




Изучение зарастаемости шхерной литорали макрофитами




Изучение ветландов (оценка зарастаемости берегов)



Изучение ветландов (оценка зарастаемости берегов)



Учет численности ладожской нерпы



Анализ поведения ладожской нерпы

Рис. 3. Примеры аэрофотоснимков для решения задач аэролимнологии (анализ водной растительности и гидрофауны)

Открывается возможность оперативной идентификации, картирования распределения крупных представителей гидрофауны (водных млекопитающих, крупных рыб) и изучения их сезонных, долговременных миграций и динамики изменения популяций [10, 14, 15].

Еще одним направлением является изучение твердых наносов в толще воды [12, 16]. Изучение температурных полей водных масс является важным этапом при проведении гидрологических исследований и понимании процессов перераспределения водных масс, связанных с потоками вещества и энергии [17].

Накопленная многолетняя картографическая информация позволяет гидрологам изучить факторы, влияющие на характер речного стока, средние уклоны поверхностей водосборов, исследовать русловые процессы, определить плановые деформации речных русел, измерить высоты бровок речных долин и обрывов, глубины рек и водоемов на мелководных участках.

Описанные выше аспекты изучения водоемов являются актуальными для комплексного исследования пресных водоемов, в том числе Ладожского озера, и определяют необходимость создания аэролимнологических информационно-измерительных средств на базе БПЛА. При этом существует несколько подходов к их разработке. Например, создание многоцелевых комплексных устройств, но как правило дорогостоящих, или же проектирование узкоспециализированных меньшей стоимости оборудования и модульных принципов монтажа данных устройств на самих БПЛА [18].

Наличие полноценно укомплектованных технических средств аэролимнологической информационно-измерительной системы позволит решать спектр задач, которые возникают в ходе проведения различных лимнологических исследований. Далее рассмотрим вклад каждой из указанных на рисунке 1 ключевых наук (робототехника, лимнология, информатика) в аэролимнологию.

2. Перспективные воздушные робототехнические средства в решении задач аэролимнологии. На рисунке 4 приведены существующие виды воздушных робототехнических средств и перспективные способы их применения в аэролимнологии. В настоящее время применяются и развиваются различные конструкции БПЛА: аэростаты, мультикоптеры, самолеты с прямым крылом, самолёты вертикального взлёта и посадки, конвертопланы, отличающиеся скоростью и дальностью полета, возможностью зависания над объектом интереса или отбора пробы в заданной точке на определенной глубине [19–22].

Поэтому выбор БПЛА во многом зависит от цели аэролимнологического исследования, удаленности и протяженности изучаемого объекта или процесса. В зависимости от размеров исследуемого пространства, частоты дискретизации создаваемой карты измерений, допустимого времени полета и всей экспедиции могут применяться один или несколько БПЛА, соответственно для их управления привлекаются методы управления одиночным, групповым, роевым управлением БПЛА [23–25].

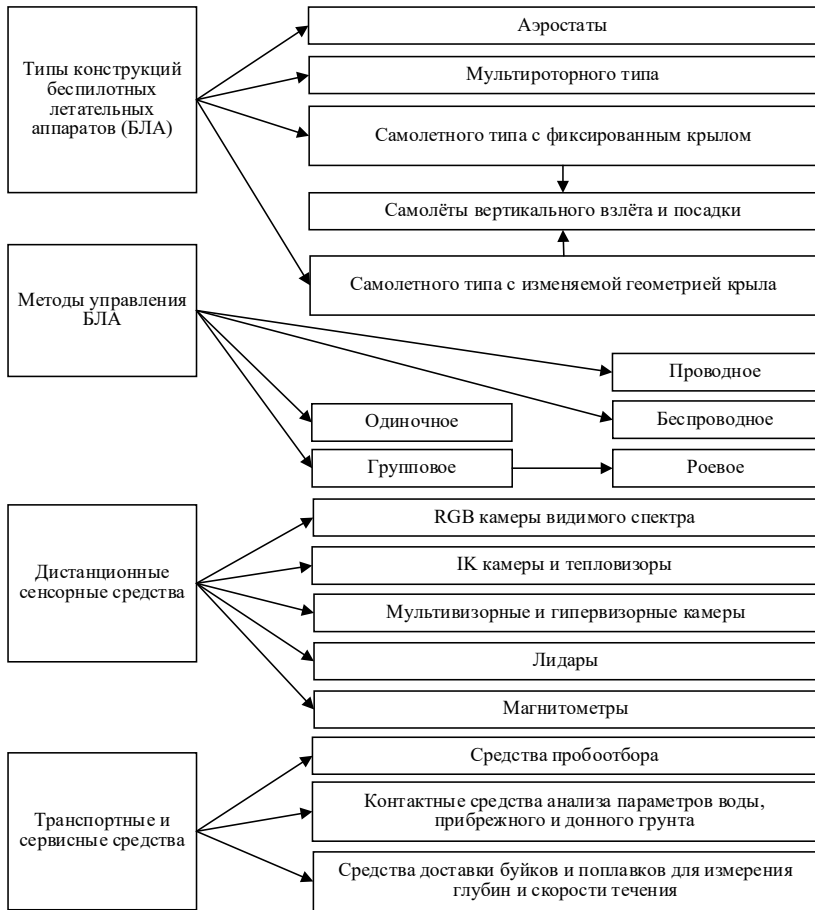


Рис. 4. Применение воздушных робототехнических средств в аэролимнологии

Для изучения отдельного объекта в ограниченной зоне как правило достаточно применения одного БПЛА. В случае анализа территориально распределенного объекта для ускорения процесса, например, при создании ортофотоплана большого участка, или для повышения точности одновременного подсчёта особей гидрофауны во всем водоёме, например, нерп, применяются несколько БПЛА, согласованно решающих целевую задачу. В этом случае используются методы группового управления: 1) централизованного, при котором каждый БПЛА получает команды с единого пульта управления; 2) децентрализованного, при котором каждый БПЛА действует

самостоятельно, принимая решения на основе своих знаний и сенсорных данных. Последний вариант характерен для роевого управления, требующего значительных вычислительных ресурсов на борту каждого БПЛА, обеспечивающих их интеллектуального и оперативность принятия решений, не теряя времени на передачу данных к центральному командному пункту и обратно.

Управление взлетом, посадкой и обслуживанием БПЛА на прибрежных участках, судне, надводных аппаратах и плавучих платформах значительно отличаются от эксплуатации и функционирования БПЛА при мониторинге земельных участков, удалённых от водоёмов. Нестабильность поверхности, куда должен приземлиться БПЛА, требует создания алгоритмов формирования более точных и оперативных движений, а также механизмов демпфирования и надёжного захвата БПЛА на надводной сервисной взлетно-посадочной платформе. Также следует учитывать повышенную влажность, брызги, риски потери БПЛА при падении в воду, сильный порывистый ветер и другие неблагоприятные возмущающие факторы, требующие от разработчиков и операторов формирования надёжных алгоритмов и сценариев управления БПЛА при составлении и реализации полетных заданий.

Для управления, электропитания, записи регистрируемых данных иногда допускается применение подключаемых по информационно-энергетическому кабелю БПЛА, в частности для стационарных объектов изучения [26]. В большинстве же случаев применяются автономные источники питания и беспроводные средства связи WiFi, LoraWan, GSM и другие [27–30].

Наиболее популярными бесконтактными сенсорными системами являются видеокamеры, регистрирующие изображения или осуществляющие видеозапись в видимом спектре [31]. Видеокamеры, установленные на БЛА, позволяют вести съёмку на заданной высоте при исследовании гидрологических объектов. Оценивание термальных процессов производится посредством ИК камер и тепловизоров. Анализ фитопланктона, химических процессов в водных и прибрежных средах производится по изображениям, полученным мульти- и гипервизорными камерами. Проведение геолого-геофизических работ становится возможным с помощью БПЛА с бортовым магнитометром. Оценивание рельефа дна и прибрежной зоны с высокой точностью производится на основе данных, полученных лидаром.

Кроме рассмотренных выше вариантов бесконтактного дистанционного измерения, также перспективны подходы

использования БПЛА на основе физического взаимодействия с наземной/водной средами. Актуальным будущим направлением является оснащение БПЛА устройствами и системами активного взаимодействия с внешними объектами – манипуляторами и захватами. Сброс, опускание, подъем из водной среды навесного оборудования БПЛА являются сложными задачами управления БПЛА, решающими проблему стабилизации воздушной манипуляционной системы, включающей БПЛА и навесное оборудование, взаимодействующее с наземной средой [32]. При сбросе буйков и поплавков, применяемых при измерении глубин и скорости течения, меняется общая масса воздушной системы, и этот фактор следует учитывать, как в локальных алгоритмах стабилизации полета, так и при планировании полетного задания с учетом снижения массы полезной нагрузки и потребляемой энергии после ее сброса.

Более сложной и энергозатратной задачей является отбор проб воды и донных отложений с БПЛА. Так как БПЛА может работать на определенных минимальных высотах над водной поверхностью, то перспективным видится применение тросовых систем, опускающих пробоотборник с БПЛА в заданное местоположение [33, 34]. В зависимости от применяемых гидрохимических аналитических средств обработка проб может производиться на борту или на наземном стационарном пункте после возвращения БПЛА. Первый вариант более оперативный и не требует перевозки проб, но влияет на стоимость оснащения БПЛА.

БПЛА как и все технические средства требуют обслуживания и пополнения энергоресурсов. Разрабатываемые сервисные наземные робототехнические платформы частично решают эти задачи, в частности замену аккумуляторов БПЛА, что значительно увеличивает продолжительность выполнения целевых задач БПЛА, кроме того снижают влияние человеческого фактора, в том числе снижая длительность нахождения участников экспедиции в районах сильного распространения гноса. Проводимые исследования по заряжающим сервисным робототехническим платформам открывают возможность применения БПЛА для обслуживания систем энергопитания, в том числе подводных и надводных роботов [35].

3. Перспективные лимнологические подходы в решении задач аэролимнологии. Лимнология, или озероведение – наука о континентальных водоемах с замедленным водообменом (озёра, водохранилища, пруды и др.). Предметом изучения лимнологии является весь комплекс внутриводоемных, или лимнических процессов, протекающих в озере в тесной связи с водосбором.

Лимнология исследует строение и развитие котловин и берегов водоёмов, донные отложения, физические и химические свойства воды, особенности водного режима (уровень воды, водный баланс), термику водоёмов, ледовые явления, гидрохимические свойства, животный и растительный мир, влияние на водоёмы деятельности человека, занимается изысканием рационального использования водоемов и их охраны. Научные основы лимнологии заложены в 19 веке работами швейцарского учёного Ф. Фореля.

Озера представляют собой сложные гидрологические и гидроэкологические системы. Поэтому для изучения озер применяется целый комплекс методов исследований из гидрологии, гидрофизики, гидрохимии, гидробиологии, геоморфологии, метеорологии, палеолимнологии и других наук [36].

На рисунке 5 приведена классификация основных способов, методов и средств, применяемых лимнологических исследований. Исходными данными для лимнологических знаний являются материалы наблюдений на озёрных станциях, постах, в обсерваториях, материалы, получаемые во время экспедиционных исследований, при проведении аэрофотосъёмки, подводных исследований, результаты физического и математического моделирования процессов, протекающих в водоёмах.

С точки зрения организации проведения лимнологических исследований можно выделить следующие подходы:

- Стационарные исследования озер и водохранилищ ведутся на озерных станциях и гидрологических постах.

- Полустанционарные исследования, как правило, сопровождают стационарные исследования, проводятся сезонно по специальной программе в соответствии с поставленными практическими и научными задачами.

- Экспедиционные исследования ведутся в связи с научными задачами научных учреждений. Исследования проводятся эпизодически, или сезонно, решаются конкретные научные задачи.

- Комплексный лимнологический метод изучения озер и водохранилищ включает ряд приемов картирования озер, донных отложений, водной растительности и прочей биоты, картографирование рельефа, измерение форм рельефа, регистрация и анализ рельефообразующих, термических, гидродинамических, геологических, химических, гидробиологических процессов, методики химического и биологического анализа донных отложений и озерных вод и другие современные методики [37].

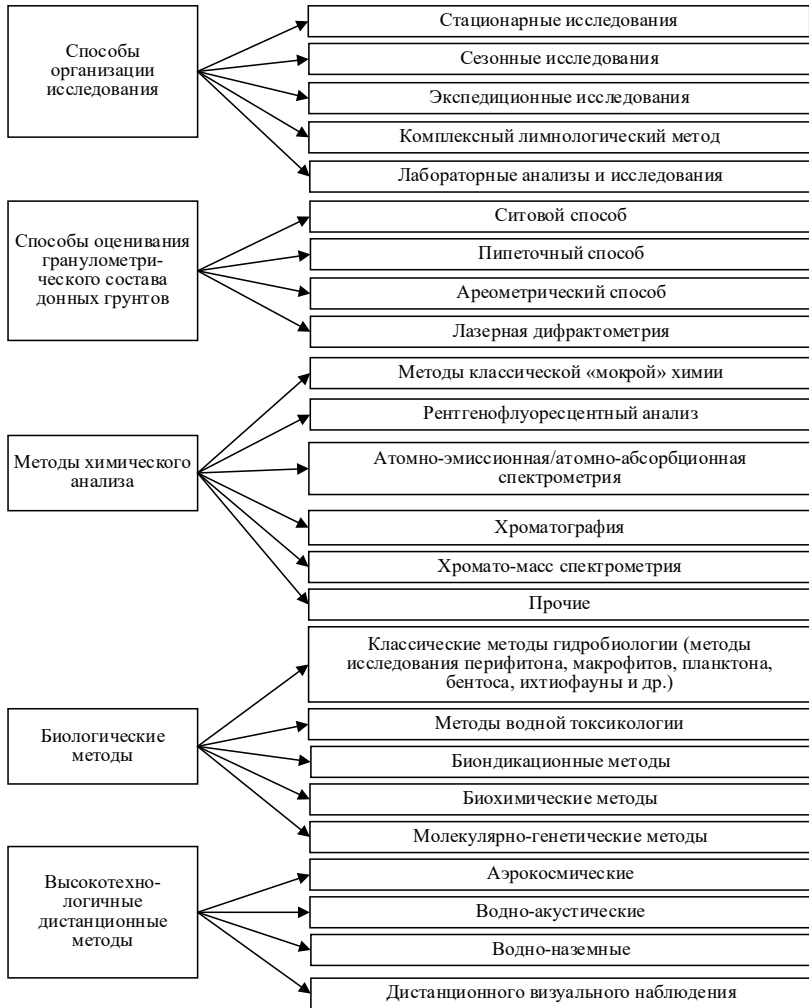


Рис. 5. Основные способы и методы лимнологических исследований

– Лабораторные анализы и исследования направлены на определение физических и химических свойств грунтов и воды, выявление состава водной биоты из проб, полученных в полевых условиях (в частности во время экспедиционных работ). Для выявления природных закономерностей и изучения влияния отдельных факторов проводятся лабораторные эксперименты, где

создаются контролируемые условия. В последние десятилетия происходит бурный рост по созданию нового аналитического оборудования, что позволяет уходить от классических методов. На сегодняшний день широко используется современная приборная база, основанная на новых принципах. Так, при оценке гранулометрического состава донных осадков водных объектов классические методы (ситовой, пипеточный, ареометрический и др.) сменяются использованием метода, основанного на применении многофункциональных анализаторов частиц (лазерная дифрактометрия в воде на основе использования физического принципа рассеяния электромагнитных волн различной длины). К современным методам химического анализа донных осадков относятся: рентгенофлуоресцентный анализ (РФА) – один из современных спектроскопических методов исследования вещества с целью получения его элементного состава; атомно-эмиссионная/масс-спектрометрия; спектрометрия с индуктивно-связанной плазмой (ICP AES or ICP MS); атомно-абсорбционная спектрометрия (ААС) [38]. При анализе биологических проб применяется спектр биологических методов, имеющий свою специфику для каждой конкретной биологической группировки (макрофиты, фитопланктон, зоопланктон, перифитон, мейо- и макробентос и пр.) [39–41]. Гидробиологические методы оценки качества вод имеют длительную историю, в значительной мере совпадающую с историей становления гидробиологии как самостоятельной науки [42]. Для исследований биологических систем, изучения отдельных видов и популяций используются также современные молекулярно-генетические методы [43]. Для изучения физико-географических условий водосборов озер в голоцене в лимнологии используется комплекс микропалеолимнологических методов: спорово-пыльцевой, диатомовый, остракодовый, палеокарпологический и др. Для определения абсолютного возраста отложений используется радиоуглеродный метод [38].

При изучении отдельных процессов широко внедряются в изучение озер и водохранилищ математическое моделирование [44, 45]. В меньшей степени используется натурное или физическое моделирование. При натурном моделировании проводятся эксперименты максимально приближенные к естественным условиям водоема. Например, использование меченого песка в прибрежной зоне с целью изучения динамики течений и транспорта наносов в прибрежной зоне [37].

В последнее время к традиционным направлениям лимнологии начали добавляться приемы, связанные с использованием современных технологий, позволяющих активно использовать дистанционные методы для изучения водных объектов. Дистанционное обследование представляет собой процесс, посредством которого собирается информация об объекте, территории или явлении без непосредственного контакта с ним. К дистанционным методам относят все виды неконтактных съемок, которые проводятся с различных измерительных платформ: летательных воздушных и космических аппаратов (беспилотных летательных аппаратов, самолетов, вертолетов, космических кораблей, спутников и т.д.), судов и подводных лодок, наземных станций [46]. По местонахождению систем получения информации и используемой технологии дистанционные методы, используемые в лимнологии, относятся к четырем основным группам: аэрокосмические (аэросъемка и спутниковая съемка с использованием большого разнообразия устройств, работающих на различных физических принципах), водно-акустические (предполагает изучение водной среды и дна с использованием различных акустических приборов – эхолотов, гидролокаторов, локаторов бокового обзора, геолокаторов), водно-наземные (использование различных автоматических буйковых станций, автономных дрейфующих станций, автономных измерителей течений и прочих приборов, оснащенных помимо датчиков современными робототехническими модулями) и методы дистанционного визуального наблюдения за водоемом (видеосъемка с обитаемых и необитаемых подводных аппаратов или аквалангистами) [3, 47–55].

4. Перспективные информационные технологии в решении задач аэролимнологии. Современные методы лимнологических исследований позволяют получать пространственные данные и обрабатывать их в геоинформационных системах (ГИС), которые обеспечивающие сбор, хранение, обработку, визуализацию и распространение данных, а также получение на их основе новой информации и знаний о пространственно-координированных объектах, процессах и явлениях [56]. Средства ГИС дают широкие возможности для получения новых знаний и представлений о природе пространственных данных и могут иметь выход на решение широкого спектра практических задач [57, 58]. Перспективным направлением в развитии ГИС является интеграция методов поддержки принятия решений, основанных на технологиях и методах искусственного интеллекта (ИИ) [56].

Важным блоком работы с пространственными данными является визуализация цифровых моделей, создаваемых средствами ГИС. Существует достаточно большая линейка программных продуктов, как открытого доступа, так и коммерческие платформы, предназначенных для построения ГИС. По способу работы с данными и возможностям организации совместной работы с данными в компьютерной сети существуют несколько технологических схем построения ГИС. Наиболее прогрессивная на сегодняшний день основана на использовании в качестве хранилища пространственных данных специализированных расширений для наиболее распространенных SQL серверов, которые на сегодня имеются у всех основных поставщиков подобных решений [58].

Пространственные данные в ГИС представляются в виде интерактивных карт. Картографические изображения на видеозэкране компьютера, возникающие как результат визуализации цифровых данных о пространственно распределенном объекте, обозначаются как электронные карты. Электронные карты, в том числе организованные в виде электронных атласов, находятся в сфере обоюдных интересов картографии и информатики [56, 60–66].

В основу созданного при СПб ФИЦ РАН центра коллективного пользования научным оборудованием «Северо-Западный центр мониторинга и прогнозирования развития территорий» положена информационно-аналитическая платформа интегрированного наземно-космического мониторинга экосистем, обеспечивающая поддержку принятия решений при управлении территориями, в том числе [67–72]: комплексное моделирование и многокритериальное оценивание, анализ и адаптивное прогнозирование рисков аварий и катастроф в природно-технических системах; обеспечение устойчивого и гармоничного использования биологических природных ресурсов в условиях интенсивного хозяйственного развития и климатических изменений; анализ влияния изменений климата на безопасность населения, экосистем, сельское хозяйство; мониторинг и оценивание индивидуальных экономико-демографических и психологических характеристик общества, определяемых методами искусственного интеллекта. На рисунке 6 и 7 показаны примеры карт типизации берегов и геоморфологии Ладожского озера, размещенные на сайте центра коллективного пользования СПб ФИЦ РАН [73].




Рис. 6. Карта типизации берегов Ладожского озера на сайте ЦКП СПб ФИЦ РАН

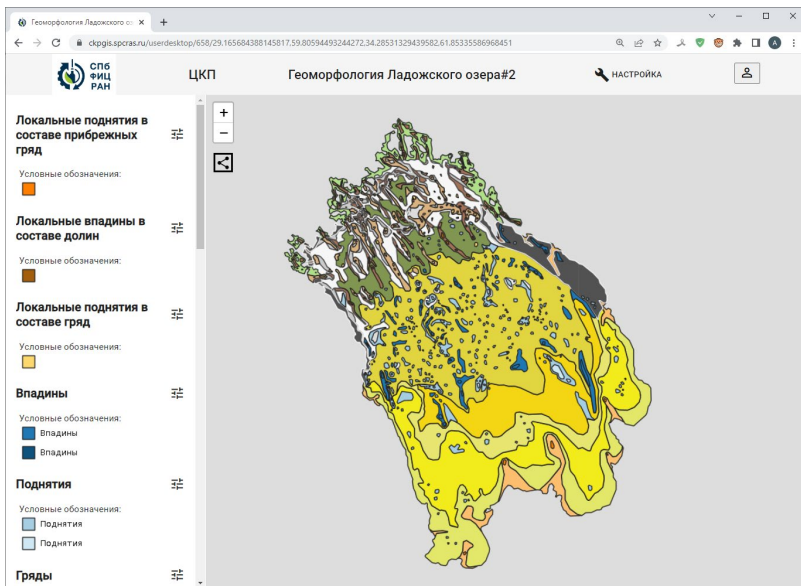


Рис. 7. Карта геоморфологии Ладожского озера на сайте ЦКП СПб ФИЦ РАН

Для решения задач лимнологии с использованием пространственной наиболее перспективными являются цифровые технологии создания ортофотопланов на основе фото- и видеосъемки в видимом спектре с БПЛА. Документально точно и оперативно передаваемый облик местности является базовым материалом для картографической основы в масштабах от 1:500 до 1: 10 000 при формировании и обновлении цифровых карт. Использование классических методов фотограмметрии и программного обеспечения позволяют достигать высокой точности и контроля этапов обработки изображений аэрофотосъемки [74–77]. На рисунке 8 представлена классификация основных подходов к обработке данных, извлечению знаний и источников информационных ресурсов, реализованные в виде специализированных информационных технологий, которые востребованы при решении задач в области аэролимнологии.



Рис. 8. Применение информационных технологий в аэролимнологии

Один из перспективных подходов к поиску информации, совмещающей пространственные и временные характеристики, извлечению знаний и проектированию когнитивных систем поддержки принятия решений основан на применении онтологий [78].

Также сведения об интересующих объектах, их историческому развитию можно получить из информационных ресурсов, в том числе порталов открытых данных (ОД), например, портал ОД России, Санкт-Петербурга, Москвы и т.д. Существует ряд открытых географических баз данных: SRTM (Shuttle Radar Topography Mission) — цифровая модель рельефа (<https://ers.cr.usgs.gov>), GIS-Lab - свободные данные по границам субъектов РФ (<https://gis-lab.info/qa/rusbounds-rosreestr.html>). Архивы метеоданных можно найти в базах NOAA National Centers for Environmental Information (NCEI) и ВНИИГМИ-МЦД (1880-2009 гг. с точностью до города), «Погода России». ЦКП Института космических исследований РАН.

5. Методология проведения аэролимнологических исследований: возможности и ограничения. Среди ограничений, накладываемых на использование беспилотных летательных аппаратов при пробоотборе и мониторинге прибрежных водных территорий, следует выделить: погодные-климатические, временные, пространственные, технические.

Применение БПЛА на открытой местности осложняется погодными условиями, а в случае близости территориально больших или линейных водных объектов возникают дополнительные возмущающие факторы, как порывистый ветер, облачность, повышенная влажность, осадки, брызги, испарения, мутность воды и другие. При изучении подводных объектов, в частности на мелководье важно учитывать прозрачность воды и влияющие на нее факторы: шторм, дожди, «цветение» воды, вызванное цианобактериями, увеличение мутности, которые могут на длительное время сделать неинформативной аэрофотосъемку. При волнении водной поверхности, появлении взвешенных частиц грунта в воде границы подводных и донных объектов на изображении существенно размываются, появляются заметные искажения.

Съемка водной поверхности в связи с её отражающей способностью не одинаково эффективна в разных погодных и временных условиях. Создаваемые от солнца блики вызывают дополнительные ограничения на период съёмки. Поэтому отдельные виды видеосъемок рекомендуется проводить только в утреннее или вечернее время. Тени от деревьев и облаков на прибрежную водную поверхность существенно зашумляют изображения и снижают их

информативность. В тоже время тени на дне от подводных объектов наоборот повышают вероятность обнаружения представителей гидрофауны.

Также следует учитывать сезонность исследований [3], например, изучение деформаций речных русел путем определения береговой линии по урезу уровня воды с помощью аэрофотосъемки осуществляют в летний меженный период.

При обсуждении пространственных ограничений следует обратить внимание на протяженность самих водных объектов и их удаленность от транспортной инфраструктуры. Поэтому при расчёте полетных заданий БПЛА необходимо учитывать время полета и возвращения к месту целевой задачи мониторинга или пробоотбора.

Под техническими ограничениями понимаются возможности как БПЛА (масса полезной нагрузки, допустимое время полёта, допустимый диапазон высот, скорость и другие), так и навесного оборудования (разрешающие способности камер, регистрируемый спектральный диапазон, скорость передачи данных, точность позиционирования, возможность группового управления, наличие сервисных наземных платформ и т.д.) [79–81].

Основные этапы методологии проведения аэролимнологических исследований представлены на рисунке 9 с указанием, какие науки привлекаются к их реализации.




Рис. 9. Методология проведения аэролимнологических исследований

В зависимости цели и вида исследования составляется методика его проведения, где в том числе формулируются требования к оборудованию дистанционного измерения, устанавливаемого на БПЛА. Затем производится выбор типа БПЛА, его летных характеристик, необходимых для установки целевого навесного оборудования и облета требуемой площади исследуемого объекта. С применением методов и средств информатики и робототехники формируется оптимальная траектория полетного задания БПЛА с

учетом геометрических характеристик лимнологического объекта. Для линейного объекта (река, канал, береговая линия озера и т.д.) формируется маршрут вдоль него. При облете и картировании объектов большой площади (озера, водохранилища, болота) траектория формируется так, чтобы все зоны интереса были охвачены, а количество сделанных при аэрофотосъемке снимков обеспечивало генерацию сплошной карты без аномалий на стыке кадров.

Выполнение полетного задания проводится одним или несколькими БПЛА с привлечением наземной, надводной техники, по итогам которого эксперты получают либо массив данных, либо проб для последующих аналитических исследований, подробно представленных на рисунке 5. При обработке и визуализации данных ученые и специалисты с применением технологий машинного обучения и искусственного интеллекта получают новые знания об исследуемом объекте и корректируют методики последующих экспериментов и экспедиций.

6. Заключение. Развитие нового научного направления аэролимнологии представляет несомненный интерес для гидробиологов, геологов и геофизиков, геоморфологов, гидрологов, геохимиков. Одновременный сбор данных при аэросъемке акватории и прибрежных территорий позволяет реализовать комплексный подход к лимнологическим исследованиям и находить новые знания на стыке различных научных дисциплин.

Научная новизна представленного исследования состоит в попытке интеграции междисциплинарных знаний при использовании беспилотных летательных аппаратов и обработке полученных данных на основе технологий искусственного интеллекта при изучении лимнологических объектов и процессов. Методология аэролимнологических исследований и прежде всего составление полётного задания осуществляется совместно специалистами лимнологами, определяющими оптимальные условия аэросъемки и пробоотбора, а робототехники подбирают параметры беспилотных летательных аппаратов, удовлетворяющих требованиям для решения целевой задачи.

В зависимости от выполняемых лимнологических задач применяются различные типы БПЛА с целевым специализированным оборудованием. Наиболее простым вариантом является БПЛА, оснащенный камерой видимого спектра для получения фото- или видеоизображений для последующего составления ортофотопланов в среде ГИС и построения на их основе электронных карт береговой

зоны и выявления различных элементов литоральных биоценозов (например, степени зарастания литорали макрофитами).

Задачи исследования рельефа дна с помощью лидарных систем, выявления интенсивности развития фитопланктонных водорослей и твердых наносов с помощью гиперспектральной съемки, обнаружения крупных водных млекопитающих (например, ладожской нерпы) и изучения водных птиц с использованием тепловизорных систем, изучение термальных полей теми же тепловизорами, а также ИК-камерами, исследование магнитных свойств бортовыми магнитометрами и т.д. требуют оснащения проектируемых БПЛА всеми этими устройствами и делают их более дорогими и сложными.

Перспективным в плане технологических решений является БПЛА, оснащенные устройствами и системами активного физического взаимодействия с внешними объектами – манипуляторами и захватами, что позволит решить задачи по проведению измерений и пробоотбору в сложных условиях или при необходимости точной координатной привязки места проведения съемки и взятию образцов.

Литература

1. Городецкий В.И., Юсупов Р.М. Искусственный интеллект: метафора, наука и информационная технология // Мехатроника, автоматизация, управление. 2020. Т. 21. № 5. С. 282-293.
2. Солдатенко С.А., Юсупов Р.М., Колман Р. Кибернетический подход к проблеме взаимодействия общества и природы в условиях беспрецедентно меняющегося климата // Труды СПИИРАН. 2020. Т. 19. № 1. С. 5-42.
3. Федоров Ю.А. Аэрофотогодезические исследования водных объектов суши. Учебное пособие. Л., изд. ЛГМИ. 1991. 173 с.
4. Павлов Н.Ф. Аэрология, радиометеорология и техника безопасности. Учебник для вузов по спец. «Метеорология». Гидрометеоиздат. 1980. 432 с.
5. Белов Н.С., Данченко А.Р. Использование беспилотных летательных аппаратов при географических исследованиях. «Научно-практический электронный журнал Аллея Науки». 2017. №16. 7 с.
6. Дудакова Д.С., Дудаков М.О. Исследования биогеоценозов шхерного района Ладожского озера (на примере залива Лехмалахти) с применением метода совмещенного использования аэровидеосъемки и подводных исследований // География: развитие науки и образования Коллективная монография по материалам Международной научно-практической конференции LXVIII Герценовские чтения, посвященной 70-летию создания ЮНЕСКО. Санкт-Петербург, 2015 Издательство: Российский государственный педагогический университет им. А. И. Герцена (Санкт-Петербург). 2015. С. 179-183.
7. Фотограмметрия и дистанционное зондирование территорий Методическое пособие к лаб. раб. Пермь ФГОУ ВПО «Пермская ГСХА» 2009. 38 с.
8. Богданов К.В., Бекетова Е.Б. Применение беспилотных летательных аппаратов в геолого-геофизической разведке месторождений полезных ископаемых // Будущее Арктики начинается здесь: Сборник материалов всероссийской научно-практической конференции с международным участием «Будущее Арктики начинается здесь». Апатиты, 2019. С. 67-79.

9. Эпов М.И. Злыгостев И.Н. Применение беспилотных летательных аппаратов в аэрогеофизической разведке // Интерэкспо ГЕО-Сибирь-2012: 8 Международный научный конгресс. Новосибирск. 10-20 апр. 2012 г. 2012. Т. 2. С. 27-32.
10. Дуленин А.А., Дуленина П.А., Коцок Д.В., Свиридов В.В. Опыт и перспективы использования малых беспилотных летательных аппаратов в морских прибрежных биологических исследованиях // Труды ВНИРО. 2021. Т. 185. С. 134-151.
11. Виноградов А.Н., Егоров В.В., Калинин А.П., Родионов А.И., И.Д. Родионов, Родионова И.П. Исследование возможностей гиперспектральной съемки для мониторинга состояния водных объектов // Современные проблемы дистанционного зондирования Земли из космоса. 2017. Т. 14. № 2. С. 125–134.
12. Коновалов Б.В., Кравчишина М.Д., Беляев Н.А., Новигатский А.Н. Определение концентрации минеральной взвеси и взвешенного органического вещества по их спектральному поглощению // Океанология. 2014. Т. 54. № 5. С. 704–711.
13. Суторихин И.А., Букатый В.И., Акулова О.Б. Сезонные изменения спектральной прозрачности и концентрации хлорофилла а в разнотипных озерах // Оптика атмосферы и океана. 2014. Т. 27. № 9. С.801-806.
14. Уличев В.И., Дудакова Д.С. Мониторинг численности ладожской кольчатой нерпы (*Pusa hispida ladogensis*) в шхерном районе Ладожского озера // Всероссийская конференция по крупным внутренним водоёмам (V Ладожский симпозиум) Сб-к науч. трудов конф. Издательство: ООО "Издательство "ЛЕМА" (Санкт-Петербург). 2016. С. 431-436.
15. Уличев В.И., Дудакова Д.С., Дудаков М.О., Труханова И.С. Возможное применение технических средств дистанционного зондирования для изучения ладожской кольчатой нерпы (*Pusa hispida ladogensis*) на линных и релаксационных залежках // морские млекопитающие Голарктики. Сборник научных трудов по материалам IX международной конференции. 2018 Издательство: РОО "Совет по морским млекопитающим" (Москва). 2018. С. 198-203.
16. Коновалов Б.В. Некоторые особенности спектрального поглощения взвеси морской воды // Оптические методы изучения океанов и внутренних водоемов. Новосибирск: Наука. 1979. С. 58–65.
17. Lednev V.N., Grishin M.Ya., Pershin S.M., Bunkin A.F. Quantifying Raman OH-band spectra for remote water temperature measurements // Optics Letters. 2016. vol. 41, Issue 20. pp. 4625-4628.
18. Носов А.М., Савельев А.И., Вильянинов В.Н., Ромашова Ю.Е., Лебедев И.В., Лебедева В.В., Янин А.П., Самохвалов И.М. Опыт транспортировки компонентов крови с применением беспилотного летательного аппарата // Медицина катастроф. 2022. №3. С.65-69. <https://doi.org/10.33266/2070-1004-2022-3-65-69>.
19. Meshcheryakov R., Salomatin A., Senchuk D., Shirokov A. Scenario of search, detection, and control of invasive plant species using unmanned aircraft systems. Smart Innovation, Systems and Technologies. 2022. vol. 245. pp. 259-270.
20. Sevostyanova N., Lebedev I., Lebedeva V., Vatamaniuk I. An Innovative Approach to Automated Photo-Activation of Crop Acreage Using UAVs to Stimulate Crop Growth. Informatics and Automation. 2021. no. 6 (20). pp. 1395-1417.
21. Pshikhopov V., Medvedev M., Soloviev V. The multicopter control algorithms with unstable modes. Proceedings of 6th International Conference on Control, Decision and Information Technologies, CoDIT 2019. vol. 6. pp. 1179-1184.
22. Verba V.S. Methods for aircraft guidance with changes in control priorities. Automation and Remote Control. 2021. vol. 82. № 9. pp. 1519-1529.

23. Milyakov D., Verba V., Merkulov V., Plyashechik A. Two approaches to simulating a group flight of unmanned aerial vehicles as system with lumped and distributed parameters. Proceedings of ITNT 2020 – 6th IEEE International Conference on Information Technology and Nanotechnology, 2020. vol. 6. pp. 9253212.
24. Izhboldina V., Lebedev I., Shabanova A. Approach to UAV swarm control and collision-free reconfiguration. Smart Innovation, Systems and Technologies. 2021. vol. 187. pp. 81-92.
25. Izhboldina V., Lebedev I. Group movement of UAVs in environment with dynamic obstacles: a survey", International Journal of Intelligent Unmanned Systems, 2022 vol. ahead-of-print. no. ahead-of-print. doi: 10.1108/IJUS-06-2021-0038.
26. Vishnevsky V., Meshcheryakov R. Experience of developing a multifunctional tethered high-altitude unmanned platform of long-term operation. Lecture Notes in Computer Science. 2019. vol. 11659 LNAI. pp. 236-244.
27. Krestovnikov K., Cherskikh E., Saveliev A. Structure and circuit solution of a bidirectional wireless power transmission system in applied robotics. Radioengineering. 2021. vol. 30. no. 1. pp. 142-149.
28. Гайдук А.Р., Капустян С.Г., Плаксиенко В.С., Кабала А.Э.А. Управление группой БЛА при неопределенных запаздываниях в каналах связи // Научный вестник Новосибирского государственного технического университета. 2020. № 2-3 (79). С. 37-56.
29. Krestovnikov K., Korshunov D., Erashov A., Rogozin A. Scalable Architecture of Distributed Control System for Industrial Greenhouse Complexes. In Proceedings of the Computational Methods in Systems and Software. Springer, Cham. LNNS, 2021. vol. 231. pp. 127-132. doi: 10.1007/978-3-030-90321-3_12.
30. Denisov A., Cherskikh E. Algorithm for Placement of Wireless Network Devices for Wide Areas with Variable Soil Moisture // International Conference in Communications, Signal Processing, and Systems. – Springer, Singapore, 2022. vol. 878. pp. 18-25. doi: 10.1007/978-981-19-0390-8_3.
31. Butt M.A., Khonina S.N., Kazanskiy N.L. Recent advances in photonic crystal optical devices: a review. Optics & Laser Technology. 2021. vol. 142. p. 107265.
32. Ronzhin A., Vu Q., Nguyen V., Ngo T. Ground and Air Robotic Manipulation Systems in Agriculture. Intelligent Systems Reference Library. Springer, Cham. 2022. vol. 214. 294 p. doi: 10.1007/978-3-030-86826-0. ISBN: 978-3-030-86825-3.
33. Käslin F., Baur T., Meier P., Koller P., Buchmann N., D'Odorico P. Eugster W. Novel Twig Sampling Method by Unmanned Aerial Vehicle (UAV). Frontiers in Forests and Global Change. 2018. vol. 1. doi: 10.3389/ffgc.2018.00002.
34. Егоркин А.А., Краснобаев Ю.Л., Наумов Д.А. Проведение экологического мониторинга с применением биологических сенсоров и беспилотных летательных аппаратов. В сборнике: Актуальные проблемы биологической и химической экологии. Сборник материалов VI Международной научно-практической конференции. Ответственный редактор Д.Б. Петренко. 2019. С 262-266.
35. Крестовников К.Д., Ерашов А.А. Исследование эффективности беспроводной системы передачи энергии при эксплуатации в воде и растворах // Датчики и системы. 2022. № 2 (261). С. 19-27.
36. Трифонова И.С. Основные этапы развития лимнологии в России до середины XX века // Труды Карельского научного центра РАН. 2018. № 9. С. 115-125.
37. Лопух П.С., Якушко О.Ф. Общая лимнология Учебное пособие. Минск: Наука. 2011. 248 с.
38. Шелехова Т.С., Слукровский З.И., Лаврова Н.Б. Методы исследования донных отложений озер Карелии / Петрозаводск: Карельский научный центр РАН, 2020. 111 с.

39. Абакумов В.А. Руководство по гидробиологическому мониторингу пресноводных экосистем / Под ред. Абакумова В.А. СПб.: Гидрометеоздат. 1992. 318 с.
40. Курашов Е.А. Методы и подходы для количественного изучения пресноводного мейобентоса // Актуальные вопросы изучения микро-, мейзообентоса и фауны зарослей пресноводных водоемов. Тематические лекции и материалы I Международной школы-конференции Россия Борок, 2-7 октября 2007 г. – Нижний Новгород: Вектор ТиС. 2007. С. 5-35.
41. Плотников Г.К., Пескова Т.Ю., Шкуте А., Пупиня А., Пупиньш М. Сборник классических методов гидробиологических исследований для использования в аквакультуре. Daugavpils universitātes akadēmiskais apgāds “Saulē”, 2017. 282 с.
42. Леонтьев В.В. Краткий курс лекций по гидробиологии. Учебное пособие для студентов-бакалавров биологических направлений Елабуга. 2015. 90 с.
43. Доменюк В.П., Гончаров А.Ю. Проблемы и перспективы использования молекулярно-генетических методов в гидробиологических исследованиях // Экология моря. 2005. № 68. С. 48-52.
44. Кондратьев С.А. Формирование внешней нагрузки на водоемы: проблемы моделирования. – СПб.: Наука. 2007. 255 с.
45. Астраханцев Г.П., Меншуткин В.В., Петрова Н.А.. / Моделирование экосистем больших стратифицированных озер. Л.А. Руховец. СПб: Наука, 2003. 361 с.
46. Сутырина Е.Н. Дистанционное зондирование Земли: учеб. пособие / Иркутск: Изд-во ИГУ, 2013. 165 с.
47. Галошин А.И. Современное состояние и тенденции развития гидрографо – геодезического обеспечения морских геологоразведочных работ // Успехи современного естествознания. 2002. № 2. С. 10-21.
48. Долинская Е.М., Бирицкая С.А., Теплых М.А., Ермолаева Я.К., Карнаухов Д.Ю., Зилов Е.А. Дистанционный подход в проведении гидробиологических исследований: от видеосъемки и эхолотирования до применения искусственного интеллекта и методов молекулярной биологии // Байкальский зоологический журнал. 2020. № 2 (28). С. 5-11.
49. Комплексный дистанционный мониторинг озерю Сб.науч.тр. / Отв.ред. Кондратьев К.Я. Л.: Изд-во Наука, 1987. 288 с.
50. Костяной А.Г., Лаврова О.Ю., Митягина М.И. Дистанционное зондирование океанов и морей // Земля и Вселенная. 2011. № 5. С. 33-44.
51. Лаврова О.Ю., Митягина М.И., Каримова С.С., Бочарова Т.Ю. Применение радиолокаторов RADARSAT-2 и TerraSAR-X для исследования гидродинамических процессов в океане // Современные проблемы дистанционного зондирования Земли из космоса. 2012.Т 9. № 2. С. 312-323.
52. Мишев Д. Дистанционные исследования Земли из космоса. М.: 1985. 229 с.
53. Новые идеи в океанологии / Ин-т океанологии им. П.П. Ширшова. М.: Наука. Т. 1: Физика. Химия. Биология / Отв. ред. М.Е. Виноградов, С.С. Лаппо, 2004. 351 с.
54. Рыбалко А.Е., Токарев М.Ю., Субетто Д.А., Алешин М.И., Беляев П.Ю., Савельева Л.А., Кузнецов В.Ю. Использование сейсмоакустических методов при изучении крупных озер для решения стратиграфических, палеогеографических и геоэкологических задач // озеро Евразии: проблемы и пути их решения Материалы II Международной конференции. Издательство: Академия наук Республики Татарстан (Казань), 2019. С. 314-318.
55. Черных Д.В. Разработка методов и программных средств акустического зондирования водной толщи и дна океана в зонах разгрузки метана. М., 2014. 167 с.

56. Каправлов Е.Г., Кошкарев А.В, Тикунов В.С. и др. Геоинформатика: Учеб.для студ.вузов / под ред В.С. Тикунова М.: Издатцентр «Академия», 2005. 480 с.
57. Зеленцов В.А., Потрысаев С.А., Пиманов И.Ю. Выбор архитектуры систем интеграции разнородных информационных ресурсов при комплексном моделировании природно-технических объектов // Информатизация и связь. 2021. № 7. С. 72-77.
58. Zelentsov V.A., Alabyan A.M., Krylenko I.N., Pimanov I.Y., Ponomarenko M.R., Potryasaev S.A., Semenov A.E., Sobolevskii V.A., Sokolov B.V., Yusupov R.M. A model-oriented system for operational forecasting of river floods. Herald of the Russian Academy of Sciences. 2019. vol. 89. № 4. pp. 405-417.
59. Мыльников Д.Ю. Геоинформационные платформы. 3-я ред. // Политерм [Электронный ресурс]. – Режим доступа: https://www.politerm.com/articles/obzor_gis.pdf
60. Zakharov K., Saveliev A. Algorithm for Edge Detection of Floodable Areas, Based on Heightmap Data // 16th International Conference on Electromechanics and Robotics "Zavalishin's Readings" (ER(ZR)-2021). 2021. vol. 232. pp. 211-222. doi: 10.1007/978-981-16-2814-6_19
61. Krylenko I., Alabyan A., Aleksyuk A., Sazonov A., Zavyalova E., Belikov V., Pimanov I., Potryasaev S., Zelentsov V. Modeling ice-jam floods in the frameworks of an intelligent system for river monitoring. Water Resources. 2020. vol. 47. № 3. pp. 387-398.
62. Zelentsov V.A., Potryasaev S.A., Pimanov I.Y., Ponomarenko M.R. Integrated use of GIS, remote sensing data and a set of models for operational flood forecasting. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 2019. pp. 477-483.
63. Mochalov V.F., Grigorieva O.V., Markov A.V., Ivanets M.O., Zelentsov V.A. Intelligent technologies and methods of tundra vegetation properties detection using satellite multispectral imagery. Advances in Intelligent Systems and Computing. 2019. vol. 986. pp. 234-243.
64. Zelentsov V.A., Potryasaev S.A., Semenov A.E. Information system for analyzing negative impacts on forests of the border regions // IOP Conference Series: Earth and Environmental Science. vol. 806, p. 012001. doi:10.1088/1755-1315/806/1/012001.
65. Sobolevskii V.A. The system of convolution neural networks automated training // CEUR Workshop Proceedings. 2021. vol. 2803. p. 100-106. doi 10.24412/1613-0073-2803-100-106.
66. Mikhailov V., Ponomarenko M., Sobolevsky V. Simulation of phytomass dynamics of plant communities based on artificial neural networks and NDVI // Recent Advances in Environmental Science from the Euro-Mediterranean and Surrounding Regions (2nd Edition). Proceedings of 2nd Euro-Mediterranean Conference for Environmental Integration (EMCEI-2), Tunisia, 2019. Springer, 2021. p. 1335-1339. doi: 10.1007/978-3-030-51210-1_211.
67. Ронжин А.Л., Зеленцов В.А., Богомолов А.В., Кулешов С.В. Технологии визуализации, обработки пространственных данных, мониторинга и проактивного управления развитием экосистем Северо-Западного региона. В сборнике: Информационные технологии и высокопроизводительные вычисления. Материалы VI Международной научно-практической конференции. Редакция: П.В. Намм (отв. редактор) [и др.]. Хабаровск. 2021. С. 207-213.
68. Sokolov B.V., Zakharov V.V., Krylov A.V., Salukhov V.I. Models and algorithms for planning and scheduling of complex objects functioning and modernization. Lecture Notes in Networks and Systems. 2022. vol. 330 LNNS. pp. 610-618.

69. Sokolov B.V., Yusupov R.M. Scientific basis of management and cybernetics methodologies integration. *Lecture Notes in Networks and Systems*. 2022. vol. 442 LNNS. pp. 52-59.
70. Ogij O.G., Osipov V.Y., Tristanov A.B., Zhukova N.A. Tasks and performance indicators of intelligent neural network support for decisions on managing labor potential of the fishery complex. *Marine intelligent technologies*. 2021. № 4-4 (54). pp. 73-79.
71. Nagoev Z.V., Nagoeva O.V., Pshenokova I.A., Bzhikhatlov K.C., Gurtueva I.A., Kankulov S.A. Multiagent neurocognitive models of the processes of understanding the natural language description of the mission of autonomous robots. *Studies in Computational Intelligence*. 2022. vol. 1032 SCI. pp. 327-332.
72. Nagoev Z., Pshenokova I., Nagoeva O., Sundukov Z. Learning algorithm for an intelligent decision making system based on multi-agent neurocognitive architectures. *Cognitive Systems Research*. 2021. vol. 66. pp. 82-88.
73. Dudakova D., Anokhin V., Dudakov M., Judin S. Mapping Rocky Coastal Landscapes in Northern Lake Ladoga around the islands of Raipatsaari and Lussikainluoto // *GEOHAB 2019 Marine geological and biological habitat mapping*. Saint-Petersburg. Russia. May 13-17. 2019. p.51-52.
74. Ламков И.М., Чермошеницев А.Ю., Арбузов С.А., Гук А.П. Исследование возможностей применения квадрокоптера для съемки береговой линии обводненного карьера с целью государственного кадастрового учета // *Вестник СГУГиТ*. 2015. Т. 1 (29). С. 200-209.
75. Овчинникова Н.Г., Ниценко И.А. Использование беспилотных летательных аппаратов в мониторинге водных объектов. Экономика и экология территориальных образований. 2022. Т.6. № 1. С. 87–94.
76. Отчет о работе по теме «Оценка возможности создания опытного района применения беспилотных авиационных систем для выполнения сервисно-транспортных задач» Шифр «Тайга 1». Томск: 2018. 138 с.
77. Рубен М.А.Э. Разработка и исследование фотограмметрических технологий мониторинга береговой линии по материалам аэрофотосъемки. М.: 2016. 97 с.
78. Volkov, A., Teslya, N., Moskvitin, G., Brovin, N., Bochkarev, E. Spatio-temporal Data Sources Integration with Ontology for Road Accidents Analysis. *Lecture Notes in Business Information Processing*. 2022. vol. 444 LNBIP. pp. 251–262. https://doi.org/10.1007/978-3-031-04216-4_23.
79. Erashov A., Krestovnikov K. Algorithm for controlling manipulator with combined array of pressure and proximity sensors in gripper // *Electromechanics and Robotics*. 2021. vol. 232. pp. 61-71. doi: 10.1007/978-981-16-2814-6_6.
80. Krestovnikov K., Cherskikh E., Bykov A. Approach to Choose of Optimal Number of Turns in Planar Spiral Coils for Systems of Wireless Power Transmission // *Elektronika ir Elektrotechnika*. 2020. vol. 26. no. 6. doi: 10.5755/j01.eie.26.6.26181.
81. Kozyr P., Erashov A., Saveliev A. Algorithm for Determining Target Point of Manipulator for Grasping an Object Using Combined Sensing Means. *Lecture Notes in Networks and Systems / Data Science and Intelligent Systems*. 2021. vol. 231. pp. 337-350. doi: 10.1007/978-3-030-90321-3_27.

Дудакова Дина Сергеевна — канд. биол. наук, научный сотрудник, лаборатория гидробиологии, ИНОЗ РАН - СПб ФИЦ РАН. Область научных интересов: гидробиология, мейобентология, перифитология, изучение биологических инвазий, подводное ландшафтоведение, подводная геология и геоморфология, биогеохимия. Число научных публикаций — 98. judina-d@yandex.ru; улица Севастьянова, 9, 196105, Санкт-Петербург, Россия; п.т.: +7(812)387-0260.

Анохин Владимир Михайлович — д-р геогр. наук, ведущий научный сотрудник, лаборатория географии и гидрологии, ИНОЗ РАН - СПб ФИЦ РАН. Область научных интересов: геоморфология, геоморфологические особенности строения дна и берегов Ладожского озера. Число научных публикаций — 136. vladanokhin@yandex.ru; улица Севастьянова, 9, 196105, Санкт-Петербург, Россия; р.т.: +7(812)387-0260.

Дудаков Михаил Олегович — инженер, лаборатория комплексных проблем лимнологии, ИНОЗ РАН - СПб ФИЦ РАН. Область научных интересов: техническое обеспечение и автоматизация измерительных средств лимнологических исследований. Число научных публикаций — 34. mike814@yandex.ru; улица Севастьянова, 9, 196105, Санкт-Петербург, Россия; р.т.: +7(812)387-0260.

Ронжин Андрей Леонидович — д-р техн. наук, профессор, профессор РАН, директор, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: технологии человеко-машинного взаимодействия, искусственного интеллекта, робототехника. Число научных публикаций — 400. ronzhin@ias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-3311.

D. DUDAKOVA, V. ANOKHIN, M. DUDAKOV, A. RONZHIN
**ON THEORETICAL FOUNDATIONS OF AEROLIMNOLOGY:
STUDY OF FRESH WATER BODIES AND COASTAL
TERRITORIES USING AIR ROBOT EQUIPMENT**

Dudakova D., Anokhin V., Dudakov M., Ronzhin A. On Theoretical Foundations of Aerolimnology: Study of Fresh Water Bodies and Coastal Territories Using Air Robot Equipment.

Abstract. The integration of the methodological basis of several different sciences in interdisciplinary research is a characteristic feature of new mechanisms for solving modern applied problems. The emerging theoretical foundations of aerolimnology, as a new scientific direction, are considered from the point of view of the contribution of three key sciences to it: limnology, informatics and robotics. Classifications of methods and approaches of limnological research, airborne robotic means, and information technologies that are promising for solving problems in the field of aerolimnology are given. The task of the scientific direction of aerolimnology is formulated as the study of the possibilities and limitations of combined methods of remote sensory measurement, robotic sampling and analytical study of the parameters of freshwater ecosystems to monitor and predict the dynamics of their development. Among the main areas of aerolimnological research, the following are distinguished: the construction of orthophotomaps and photogrammetric spatial models of the bottom topography and individual elements of the bottom landscape and coastal zone of various scales; geological and geophysical mapping of the underwater part of the coastal zone; the study of phytoplankton, in particular, the "bloom" of water caused by cyanobacteria; study of distribution and migration of large representatives of hydrofauna; study of temperature fields and processes of redistribution of water masses. The limitations imposed on the use of unmanned aerial vehicles (UAVs) in sampling and monitoring coastal water areas are discussed, primarily weather-climatic, temporal, spatial, and technical. The advantage of using unmanned aerial vehicles in aerolimnology is justified by an increase in the speed of data acquisition, the possibility of approaching hard-to-reach and territorially remote objects, and a decrease in the influence of the human factor. The scientific novelty of the presented research consists in an attempt to integrate interdisciplinary knowledge when using unmanned aerial vehicles and processing the obtained data based on artificial intelligence technologies in the study of limnological objects and processes. The important role of geoinformation systems is noted and examples of maps of shore typification and geomorphology of Lake Ladoga are given, posted on the website of the Center for the Collective Use of Scientific Equipment "North-Western Center for Monitoring and Forecasting the Development of Territories" of the St. Petersburg Federal Research Center of the Russian Academy of Sciences. The main stages of the methodology for conducting aerolimnological studies using interdisciplinary approaches based on limnology, informatics and robotic tools operating in different environments are considered.

Keywords: aerolimnology, lake science, unmanned aerial vehicles, fresh water bodies, Lake Ladoga, sampling, monitoring, informatics, robotics, GIS.

References

1. Gorodetsky V.I., Yusupov R.M. [Artificial Intelligence: Metaphor, Science and Information Technology]. *Mekhatronika, Avtomatizatsiya, Upravlenie*. 2020. 21(5). pp. 282-294. doi: 10.17587/mau.21.282-293. (In Russ.).

2. Soldatenko S., Yusupov R., Colman R. [Cybernetic Approach to Problem of Interaction between Nature and Human Society in Context of Unprecedented Climate Change]. Trudy SPIIRAN – SPIIRAS Proceedings. 2020. № 1 (19). pp. 5-42. (In Russ.).
3. Fedorov Ju.A. Ajerofotogeodezicheskie issledovanija vodnyh obyektov sushi. [Aerial photogeodetic studies of land water bodies]. Uchebnoe posobie. L., izd. LGMI, 1991. 173 p. (In Russ.).
4. Pavlov N.F. Ajerologija, radiometeorologija i tehnika bezopasnosti. [Aerology, radiometeorology and safety engineering]. Uchebnik dlja vuzov po spec. «Meteorologija». Gidrometeoizdat, 1980. 432 p. (In Russ.).
5. Belov N.S., Danchenkov A.R. [The use of unmanned aerial vehicles in geographical research]. Nauchno-prakticheskij jelektronnyj zhurnal Alleja Nauki – Scientific and practical electronic journal Alley of Science. 2017. №16. 7 p. (In Russ.).
6. Dudakova D.S., Dudakov M.O. [Research of biogeocenoses of the skerry region of Lake Ladoga (on the example of the Lekhmalakhti Bay) using the method of combined use of aerial video and underwater research]. Geografija: razvitie nauki i obrazovanija Kollektivnaja monografija po materialam Mezhdunarodnoj nauchno-praktichesknoj konferencii LXVIII Gercenovskie chtenija, posvjashhennoj 70-letiju sozdanija JuNESKO – Geography: the development of science and education: Collective monograph based on the materials of the International Scientific and Practical Conference LXVIII Herzen Readings, dedicated to the 70th anniversary of the creation of UNESCO. Sankt-Petersburg: Rossijskij gosudarstvennyj pedagogicheskij universitet im. A.I. Gercena, 2015, pp. 179-183. (In Russ.).
7. Fotogrammetrija i distancionnoe zondirovanie territorij [Photogrammetry and remote sensing of territories]. Metodicheskoe posobie k lab. rab. Perm: FGOU VPO «Permskaja GSHA», 2009. 38 p. (In Russ.).
8. Bogdanov K.V., Beketova E.B. [The use of unmanned aerial vehicles in geological and geophysical exploration of mineral deposits]. Budushhee Arktiki nachinaetsja zdes': Sbornik materialov vsrossijskoj nauchno-praktichesknoj konferencii s mezhdunarodnym uchastiem «Budushhee Arktiki nachinaetsja zdes». Apatity, 2019. pp. 67-79. (In Russ.).
9. Jepov M.I. Zlygostev I.N. [The use of unmanned aerial vehicles in airborne geophysical reconnaissance]. Interjekspo GEO-Sibir-2012: 8 Mezhdunarodnyj nauchnyj congress – Interexpo GEO-Siberia-2012: 8th International Scientific Congress. Novosibirsk, 2012. vol. 2. pp. 27-32. (In Russ.).
10. Dulenin A.A., Dulenina P.A., Kocjuk D.V., Sviridov V.V. [Experience and prospects for the use of small unmanned aerial vehicles in marine coastal biological research]. Trudy VNIRO – Proceedings of VNIRO. 2021. vol. 185. pp. 134-151. (In Russ.).
11. Vinogradov A.N., Egorov V.V., Kalinin A.P., Rodionov A.I., Rodionov I.D., Rodionova I.P. [Investigation of hyperspectral survey capabilities for monitoring water bodies state and water quality]. Sovremennye problemy distantsionnoe zondirovaniya Zemli iz kosmosa – Modern problems of remote sensing of the Earth from space. 2017. vol. 14. no. 2. pp. 125-134. doi: 10.21046/2070-7401-2017-14-2-125-134. (In Russ.).
12. Konovalov B.V., Kravchishina M.D., Beljaev N.A., Novigatskij A.N. [Determination of the concentration of mineral suspension and suspended organic matter by their spectral absorption]. Okeanologija – Oceanology. 2014. vol. 54. № 5. pp. 704–711. (In Russ.).
13. Sutorikhin I.A., Bukatyj V.I., Akulova O.B. [Seasonal changes of water spectral transparency and concentration of chlorophyll a in different-type lakes]. Optika Atmosfery i Okeana – Atmospheric and ocean optics. 2014. vol. 27. no. 09. pp. 801-806. (In Russ.).

14. Ulichev V.I., Dudakova D.S. [Monitoring the abundance of the Ladoga ringed seal (*Pusa hispida ladogensis*) in the skerry region of Lake Ladoga]. Vserossijskaja konferencija po крупным vnutrennim vodojomam (V Ladozhskij simpozium) Sb-k nauch. trudov konf. [V Ladoga Symposium: Collection of scientific papers of the conference]. Sankt-Peterburg: OOO "Izdatelstvo "LEMA", 2016. pp. 431-436. (In Russ.).
15. Ulichev V.I., Dudakova D.S., Dudakov M.O., Truhanova I.S. [Possible application of technical means of remote sensing for studying the Ladoga ringed seal (*Pusa hispida ladogensis*) on moulting and relaxation haulouts]. Morskie mlekopitajushhie Golarctiki. Sbornik nauchnyh trudov po materialam IX mezhdunarodnoj konferencii [Marine mammals of the Holarctic. Collection of scientific papers]. Moskva: ROO "Sovet po morskim mlekopitajushhim", 2018. pp. 198-203. (In Russ.).
16. Konovalov B.V. Nekotorye osobennosti spektral'nogo pogloshhenija vzvesi morskoj vody [Some Features of the Spectral Absorption of Sea Water Suspension] Opticheskie metody izucheniya okeanov i vnutrennih vodoemov. Novosibirsk: Nauka, 1979. pp. 58–65. (In Russ.).
17. Lednev V.N., Grishin M.Ya., Pershin S.M., Bunkin A.F. Quantifying Raman OH-band spectra for remote water temperature measurements. Optics Letters. 2016. vol. 41. Issue 20. pp. 4625-4628.
18. Nosov A.M., Savelev A.I., Viljaninov V.N., Romashova Ju.E., Lebedev I.V., Lebedeva V.V., Janin A.P., Samohvalov I.M. [Experience in transporting blood components using an unmanned aerial vehicle]. Medicina katastrof – Emergency Medicine. 2022. № 3. pp. 65-69. doi: 10.33266/2070-1004-2022-3-65-69. (In Russ.).
19. Meshcheryakov R., Salomatin A., Senchuk D., Shirokov A. Scenario of search, detection, and control of invasive plant species using unmanned aircraft systems. Smart Innovation, Systems and Technologies. 2022. vol. 245. pp. 259-270.
20. Sevostyanova N., Lebedev I., Lebedeva V., Vatamaniuk I. An Innovative Approach to Automated Photo-Activation of Crop Acreage Using UAVs to Stimulate Crop Growth. Informatics and Automation. 2021. № 6 (20). pp. 1395-1417.
21. Pshikhopov V., Medvedev M., Soloviev V. The multicopter control algorithms with unstable modes. Proceedings of 6th International Conference on Control, Decision and Information Technologies, CoDIT 2019. vol. 6. pp. 1179-1184.
22. Verba V.S. Methods for aircraft guidance with changes in control priorities. Automation and Remote Control. 2021. vol. 82. № 9. pp. 1519-1529.
23. Milyakov D., Verba V., Merkulov V., Plyashechik A. Two approaches to simulating a group flight of unmanned aerial vehicles as system with lumped and distributed parameters. Proceedings of ITNT 2020 – 6th IEEE International Conference on Information Technology and Nanotechnology, 2020. vol. 6. pp. 9253212.
24. Izhboldina V., Lebedev I., Shabanova A. Approach to UAV swarm control and collision-free reconfiguration. Smart Innovation, Systems and Technologies. 2021. vol. 187. pp. 81-92.
25. Izhboldina V., Lebedev I. Group movement of UAVs in environment with dynamic obstacles: a survey", International Journal of Intelligent Unmanned Systems. 2022. vol. ahead-of-print. no. ahead-of-print. doi: 10.1108/IJIUS-06-2021-0038.
26. Vishnevsky V., Meshcheryakov R. Experience of developing a multifunctional tethered high-altitude unmanned platform of long-term operation. Lecture Notes in Computer Science. 2019. vol. 11659 LNAI. pp. 236-244.
27. Krestovnikov K., Cherskikh E., Saveliev A. Structure and circuit solution of a bidirectional wireless power transmission system in applied robotics. Radioengineering. 2021. vol. 30. № 1. pp. 142-149.
28. Gajduk A.R., Kapustjan S.G., Plaksienko V.S., Kabalan A.Je.A. [Control of a group of UAVs with indefinite delays in communication channels]. Nauchnyj vestnik

- Novosibirskogo gosudarstvennogo tehničeskogo universiteta – Scientific Bulletin of the Novosibirsk State Technical University. 2020. № 2-3 (79). pp. 37-56. (In Russ.).
29. Krestovnikov, K., Korshunov, D., Erashov, A., Rogozin, A. Scalable Architecture of Distributed Control System for Industrial Greenhouse Complexes. In Proceedings of the Computational Methods in Systems and Software. Springer, Cham. LNNS, 2021. vol. 231. pp. 127-132. doi: 10.1007/978-3-030-90321-3_12.
30. Denisov A., Cherskikh E. Algorithm for Placement of Wireless Network Devices for Wide Areas with Variable Soil Moisture. International Conference in Communications, Signal Processing, and Systems. Springer, Singapore, 2022. vol. 878. pp. 18-25. doi: 10.1007/978-981-19-0390-8_3.
31. Butt M.A., Khonina S.N., Kazanskiy N.L. Recent advances in photonic crystal optical devices: a review. Optics & Laser Technology. 2021. vol. 142. p. 107265.
32. Ronzhin A., Vu Q., Nguyen V., Ngo T. Ground and Air Robotic Manipulation Systems in Agriculture. Intelligent Systems Reference Library. Springer, Cham. 2022. vol. 214. 294 p. doi: 10.1007/978-3-030-86826-0. ISBN: 978-3-030-86825-3.
33. Käslin F., Baur T., Meier P., Koller P., Buchmann N., D'Odorico P., Eugster W. Novel Twig Sampling Method by Unmanned Aerial Vehicle (UAV). Frontiers in Forests and Global Change. 2018. vol. 1. doi: 10.3389/ffgc.2018.00002.
34. Egorkin A.A., Krasnobaev Ju.L., Naumov D.A. [Carrying out environmental monitoring using biological sensors and unmanned aerial vehicles]. (Russ. ed.: Petrenko D.B.) V sbornike: Aktualnye problemy biologicheskoy i himičeskoj jekologii. Sbornik materialov VI Mezhdunarodnoj nauchno-praktičeskoj konferencii [Actual problems of biological and chemical ecology: Collection of materials]. 2019. pp. 262-266. (In Russ.).
35. Krestovnikov K.D., Erashov A.A. [Investigation of the efficiency of a wireless power transmission system when operating in water and solutions]. Datchiki i sistemy – Sensors and systems. 2022. № 2 (261). pp. 19-27. (In Russ.).
36. Trifonova I.S. [The main stages in the development of limnology in Russia until the middle of the 20th century]. Trudy Karelskogo nauchnogo centra RAN – Proceedings of the Karelian Scientific Center of the Russian Academy of Sciences. 2018. № 9. pp. 115-125. (In Russ.).
37. Lopuh P.S., Jakushko O.F. Obshhaja limnologija [General limnology]. Minsk: Nauka, 2011. 248 p. (In Russ.).
38. Shelehova T.S., Slukovskij Z.I., Lavrova N.B. Metody issledovanija donnyh otlozhenij ozer Karelii [Methods for studying bottom sediments of lakes in Karelia]. Petrozavodsk: Karelskij nauchnyj centr RAN, 2020. 111 p. (In Russ.).
39. Abakumov V.A. Rukovodstvo po gidrobiologičeskomu monitoringu presnovodnyh jekosistem [Guidelines for Hydrobiological Monitoring of Freshwater Ecosystems]. (Russ. ed.: Abakumova V.A.) SPb.: Gidrometeoizdat, 1992. 318 p. (In Russ.).
40. Kurashov E.A. [Methods and approaches for quantitative study of freshwater meiobenthos]. Aktualnye voprosy izuchenija mikro-, mejozoobentosa i fauny zaroslej presnovodnyh vodoemov. Tematičeskie lekčii i materialy I Mezhdunarodnoj shkoly-konferencii Rossija Borok [Topical issues in the study of micro-, meiozoobenthos and fauna of thickets of freshwater reservoirs: Thematic lectures and materials]. Nizhnij Novgorod: Vektor TiS, 2007. pp. 5-35. (In Russ.).
41. Plotnikov G.K., Peskova T.Ju., Shkute A., Pupinja A., Pupinsh M. Sbornik klassičeskikh metodov gidrobiologičeskikh issledovanij dlja ispolzovanija v akvakulture [Compendium of classical methods of hydrobiological research for use in aquaculture]. Latvija: Daugavpils universitātes akadēmiskais apgads "Saule", 2017. 282 p. (In Russ.).
42. Leontev V.V. Kratkij kurs lekčij po gidrobiologii. Učebnoe posobie dlja studentov-bakalavrov biologičeskikh napravlenij Elabuga [A short course of lectures on

- hydrobiology. Textbook for bachelor students in biology [Elabuga]. 2015. 90 p. (In Russ.).
43. Domenjuk V.P., Goncharov A.Ju. [Problems and Prospects of Using Molecular Genetic Methods in Hydrobiological Research]. *Jekologija morja – Sea ecology*. 2005. vol. 68. pp. 48-52. (In Russ.).
 44. Kondratev S.A. Formirovanie vneshnej nagruzki na vodoemy: problemy modelirovanija [Formation of external load on water bodies: modeling problems]. SPb.: Nauka, 2007. 255 p. (In Russ.).
 45. Astrahancev G.P., Menshutkin V.V., Petrova N.A. Modelirovanie jekosistem bolshih stratificirovannyh ozer [Ecosystem modeling for large stratified lakes]. (Russ. ed.: Ruhovec L.A.). SPb: Nauka, 2003. 361 p. (In Russ.).
 46. Sutyryna E.N. Distancionnoe zondirovanie Zemli: ucheb. posobie [Earth Remote Sensing: Tutorial]. Irkutsk : Izd-vo IGU, 2013. 165 p. (In Russ.).
 47. Galoshin A.I. [Current state and development trends of hydrographic and geodetic support for offshore geological exploration]. *Uspehi sovremennogo estestvoznaniija – Successes of modern natural science*. 2002. № 2. pp. 10-21. (In Russ.).
 48. Dolinskaja E.M., Birickaja S.A., Teplyh M.A., Ermolaeva Ja.K., Karnauhov D.Ju., Zilov E.A. [Remote approach in conducting hydrobiological research: from video filming and echo sounding to the use of artificial intelligence and molecular biology methods]. *Bajkalskij zoologicheskij zhurnal – Baikral Zoological Journal*. 2020. no. 2 (28). pp. 5-11. (In Russ.).
 49. Kompleksnyj distancionnyj monitoring ozer. Sb.nauch.tr. [Complex remote monitoring of lakes. Collection of scientific papers]. (Russ. ed.: Kondratev K.Ja.) L.: Izd-vo Nauka, 1987. 288 p. (In Russ.).
 50. Kostjanov A.G., Lavrova O.Ju., Mitjagina M.I. Distancionnoe zondirovanie okeanov i morej. Zemlja i Vselennaja. 2011. no 5. pp. 33-44. (In Russ.).
 51. Lavrova O.Ju., Mitjagina M.I., Karimova S.S., Bocharova T.Ju. [Application of RADARSAT-2 and TerraSAR-X radars to study hydrodynamic processes in the ocean]. *Sovremennye problemy distancionnogo zondirovanija Zemli iz kosmosa – Modern problems of remote sensing of the Earth from space*. 2012. vol. 9. №2. pp. 312-323. (In Russ.).
 52. Mishev D. Distancionnyje issledovanija Zemli iz kosmosa [Remote sensing of the Earth from space]. M.: 1985. 229 p. (In Russ.).
 53. Novye idei v okeanologii. In-t okeanologii im. P.P. Shirshova [New ideas in oceanology. Institute of Oceanology named after P.P. Shirshova]. (Russ. ed.: Vinogradov M.E., Lappo S.S.). M.: Nauka. Fizika. Himija. Biologija, 2004. vol. 13. 51 p. (In Russ.).
 54. Rybalko A.E., Tokarev M.Ju., Subetto D.A., Aleshin M.I., Beljaev P.Ju., Saveleva L.A., Kuznecov V.Ju. [The use of seismoacoustic methods in the study of large lakes to solve stratigraphic, paleogeographic and geocological problems]. *Ozera Evrazii: problemy i puti ih reshenija: Materialy II Mezhdunarodnoj konferencii [The land of Eurasia: problems and ways to solve them: Proceedings of the conference]*. Kazan: Akademija nauk Respubliki Tatarstan, 2019. pp. 314-318. (In Russ.).
 55. Chernyh D.V. Razrabotka metodov i programmnyh sredstv akusticheskogo zondirovanija vodnoj tolshhi i dna okeana v zonah razgruzki metana [Development of methods and software tools for acoustic sounding of the water column and the ocean floor in methane discharge zones]. M.: 2014. 167 p. (In Russ.).
 56. Kapravlov E.G., Koshkarev A.V, Tikunov V.S. i dr. Geoinformatika: Ucheb. dlja stud. Vuzov [Geoinformatics: Textbook for university students]. (Russ. ed.: Tikunova V.S.). M.: Izdatcentr «Akademija», 2005. 480 p. (In Russ.).
 57. Zelencov V.A., Potrjasaev S.A., Pimanov I.Ju. [The Choice of the Architecture of Systems for Integration of Heterogeneous Information Resources in the Complex

- Modeling of Natural and Technical Objects]. Informatizacija i svjaz – Informatization and communication. 2021. № 7. pp. 72-77. (In Russ.).
58. Zelentsov V.A., Alabyan A.M., Krylenko I.N., Pimanov I.Y., Ponomarenko M.R., Potryasaev S.A., Semenov A.E., Sobolevskii V.A., Sokolov B.V., Yusupov R.M. A model-oriented system for operational forecasting of river floods. Herald of the Russian Academy of Sciences. 2019. vol. 89. № 4. pp. 405-417.
59. Mylnikov D.Ju. Geoinformacionnye platformy. 3-ja red. Politerm [Geoinformation platforms. 3rd ed. Polyterm]. Available at: https://www.politerm.com/articles/obzor_gis.pdf. (accessed 26.10.2022) (In Russ.).
60. Zakharov K., Saveliev A. Algorithm for Edge Detection of Floodable Areas, Based on Heightmap Data. 16th International Conference on Electromechanics and Robotics "Zavalishin's Readings" (ER(ZR)-2021). 2021. vol. 232. pp. 211-222. doi: 10.1007/978-981-16-2814-6_19.
61. Krylenko I., Alabyan A., Alekseyuk A., Sazonov A., Zavyalova E., Belikov V., Pimanov I., Potryasaev S., Zelentsov V. Modeling ice-jam floods in the frameworks of an intelligent system for river monitoring. Water Resources. 2020. vol. 47. № 3. pp. 387-398.
62. Zelentsov V.A., Potryasaev S.A., Pimanov I.Y., Ponomarenko M.R. Integrated use of GIS, remote sensing data and a set of models for operational flood forecasting. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 2019. pp. 477-483.
63. Mochalov V.F., Grigorieva O.V., Markov A.V., Ivanets M.O., Zelentsov V.A. Intelligent technologies and methods of tundra vegetation properties detection using satellite multispectral imagery. Advances in Intelligent Systems and Computing. 2019. vol. 986. pp. 234-243.
64. Zelentsov V.A., Potryasaev S.A., Semenov A.E. Information system for analyzing negative impacts on forests of the border regions. IOP Conference Series: Earth and Environmental Science. vol. 806. p. 012001. doi: 10.1088/1755-1315/806/1/012001.
65. Sobolevskii V.A. The system of convolution neural networks automated training. CEUR Workshop Proceedings. 2021. vol. 2803. p. 100-106. doi 10.24412/1613-0073-2803-100-106.
66. Mikhailov V., Ponomarenko M., Sobolevsky V. Simulation of phytomass dynamics of plant communities based on artificial neural networks and NDVI. Recent Advances in Environmental Science from the Euro-Mediterranean and Surrounding Regions (2nd Edition). Proceedings of 2nd Euro-Mediterranean Conference for Environmental Integration (EMCEI-2), Tunisia, 2019. Springer, 2021. p. 1335-1339. doi: 10.1007/978-3-030-51210-1_211.
67. Ronzhin A.L., Zelencov V.A., Bogomolov A.V., Kuleshov S.V. [Technologies for visualization, processing of spatial data, monitoring and proactive management of the development of ecosystems in the North-West region.]. V sbornike: Informacionnye tehnologii i vysokoproizvoditelnye vychislenija. Materialy VI Mezhdunarodnoj nauchno-prakticheskoy konferencii [Information Technology and High Performance Computing: Collection]. (Russ. ed.: Namm R.V. i dr.). Habarovsk: 2021. pp. 207-213. (In Russ.).
68. Sokolov B.V., Zakharov V.V., Krylov A.V., Salukhov V.I. Models and algorithms for planning and scheduling of complex objects functioning and modernization. Lecture Notes in Networks and Systems. 2022. vol. 330 LNNS. pp. 610-618.
69. Sokolov B.V., Yusupov R.M. Scientific basis of management and cybernetics methodologies integration. Lecture Notes in Networks and Systems. 2022. vol. 442 LNNS. pp. 52-59.
70. Ogij O.G., Osipov V.Y., Tristanov A.B., Zhukova N.A. Tasks and performance indicators of intelligent neural network support for decisions on managing labor

- potential of the fishery complex. *Marine intelligent technologies*. 2021. № 4-4 (54). pp. 73-79.
71. Nagoev Z.V., Nagoeva O.V., Pshenokova I.A., Bzhikhatlov K.C., Gurtueva I.A., Kankulov S.A. Multiagent neurocognitive models of the processes of understanding the natural language description of the mission of autonomous robots. *Studies in Computational Intelligence*. 2022. vol. 1032 SCI. pp. 327-332.
 72. Nagoev Z., Pshenokova I., Nagoeva O., Sundukov Z. Learning algorithm for an intelligent decision making system based on multi-agent neurocognitive architectures. *Cognitive Systems Research*. 2021. vol. 66. pp. 82-88.
 73. Dudakova D., Anokhin V., Dudakov M., Judin S. Mapping Rocky Coastal Landscapes in Northern Lake Ladoga around the islands of Raipatsaari and Lussikainluoto. *GEOHAB 2019 Marine geological and biological habitat mapping*. Saint-Petersburg, 2019. pp. 51-52.
 74. Lamkov I.M., Chermoshencev A.Ju., Arbuzov S.A., Guk A.P. [Study of the possibilities of using a quadrocopter to monitor the line of a flooded quarry for the purpose of state cadastral registration]. *Vestnik SGUGiT – Vestnik SGUGiT*. 2015. vol. 1 (29). pp. 200-209. (In Russ.).
 75. Ovchinnikova N.G., Nicenko I.A. [The use of unmanned aerial vehicles in the monitoring of water bodies]. *Jekonomika i jekologija territori-alnyh obrazovanij – Economics and ecology of territorial entities*. 2022. vol. 6. no 1. pp. 87–94. (In Russ.).
 76. Otchet o rabote po teme «Ocenka vozmozhnosti sozdaniya opytnogo rajona primeneniya bespilotnyh aviacionnyh sistem dlja vypolneniya servisno-transportnyh zadach» [Report "Assessment of the possibility of creating an experimental area for the use of unmanned aerial systems to perform service and transport tasks"] *Shifr «Tajga 1»*. Tomsk: 2018. 138 p. (In Russ.).
 77. Ruben M.A.Je. Razrabotka i issledovanie fotogrammetricheskikh tehnologij monitoringa beregovoj linii po materialam ajerofotosemki [Development and research of photogrammetric technologies for coastline monitoring based on aerial photography]. M.: 2016. 97 p. (In Russ.).
 78. Volkov A., Teslya N., Moskvitin G., Brovin N., Bochkarev E. Spatio-temporal Data Sources Integration with Ontology for Road Accidents Analysis. *Lecture Notes in Business Information Processing*. 2022. vol. 444 LNBIP. pp. 251–262. doi: 10.1007/978-3-031-04216-4_23.
 79. Erashov A., Krestovnikov K. Algorithm for controlling manipulator with combined array of pressure and proximity sensors in gripper. *Electromechanics and Robotics*. 2021. vol. 232. pp. 61-71. doi: 10.1007/978-981-16-2814-6_6.
 80. Krestovnikov K., Cherskikh E., Bykov A. Approach to Choose of Optimal Number of Turns in Planar Spiral Coils for Systems of Wireless Power Transmission. *Elektronika ir Elektrotehnika*. 2020. vol. 26. no. 6. doi: 10.5755/j01.eie.26.6.26181.
 81. Kozyr P., Erashov A., Saveliev A. Algorithm for Determining Target Point of Manipulator for Grasping an Object Using Combined Sensing Means. *Lecture Notes in Networks and Systems*. Data Science and Intelligent Systems. 2021. vol. 231. pp. 337-350. doi: 10.1007/978-3-030-90321-3_27.

Dudakova Dina — Ph.D., Researcher, Laboratory of hydrobiology, IL RAS - SPC RAS. Research interests: hydrobiology, meiobenthology, periphytology, study of biological invasions, underwater landscape science, underwater geology and geomorphology, biogeochemistry. The number of publications — 98. judina-d@yandex.ru; 9, Sevastyanov St., 196105, St. Petersburg, Russia; office phone: +7(812)387-0260.

Anokhin Vladimir — Ph.D., Dr.Sci., Leading researcher, Laboratory of geography and hydrology, IL RAS - SPC RAS. Research interests: geomorphology, geomorphological

features of the structure of the bottom and shores of Lake Ladoga. The number of publications — 136. vladanokhin@yandex.ru; 9, Sevastyanov St., 196105, St. Petersburg, Russia; office phone: +7(812)387-0260.

Dudakov Mikhail — Engineer, Laboratory of complex problems of limnology, IL RAS - SPC RAS. Research interests: technical support and automation of measuring instruments for limnological studies. The number of publications — 34. mike814@yandex.ru; 9, Sevastyanov St., 196105, St. Petersburg, Russia; office phone: +7(812)387-0260.

Ronzhin Andrey — Ph.D., Dr.Sci., Professor, Professor of the RAS, Director, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: human-machine interaction technologies, artificial intelligence, robotics. The number of publications — 400. ronzhin@iias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-3311.

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 разрешены. 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 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 24.11.2022. Passed for print 01.12.2022.

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 24.11.2022. Дата выхода в свет 01.12.2022.

Формат 60×90 1/16. Усл. печ. л. 12,26. Заказ № 293. 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»