

И.Н. Глухих, А.С. Прохoshин, Д.И. Глухих
**СРАВНЕНИЕ И ОТБОР СИТУАЦИЙ В СИСТЕМАХ ВЫВОДА
РЕШЕНИЙ НА ПРЕЦЕДЕНТАХ ДЛЯ «УМНОЙ» ФЕРМЫ**

Глухих И.Н., Прохoshин А.С., Глухих Д.И. Сравнение и отбор ситуаций в системах вывода решений на прецедентах для «умной» фермы.

Аннотация. Тенденция развития умных ферм направлена на их становление полностью автономными, роботизированными предприятиями. Перспективы интеллектуализации сельскохозяйственного производства и умных ферм, в частности, сегодня связываются с развитием технологий систем, применяемых для обнаружения, распознавания сложных производственных ситуаций и поиска эффективных решений в этих ситуациях. В статье рассмотрены вопросы создания ситуационных систем поддержки принятия решения на умных фермах с применением вывода решений на основе рассуждений по прецедентам (case-based reasoning). Для разработки таких систем требуется выполнение ряда нетривиальных задач, к которым относятся, прежде всего, задачи формализации представления ситуаций и построения на этой основе способов сравнения и отбора ситуаций в базах знаний. В данном исследовании умная ферма представлена как сложный технологический объект, состоящий из взаимосвязанных компонентов, которыми являются технологические подсистемы умной фермы, производимая продукция, объекты операционного окружения, а также отношения между ними. Для реализации алгоритмов ситуационного вывода решений на основе прецедентов предложено формализованное представление ситуации в виде мультивектора, который содержит информацию о состояниях этих компонентов. Это позволило разработать ряд моделей обучаемой функции схожести между ситуациями. Проведенные эксперименты показали работоспособность предложенных моделей, на основе чего разработана ансамблевая архитектура нейросети для сравнения ситуаций и их отбора из базы знаний в процессах вывода решений. Практический интерес представляет мониторинг состояния растений по их видео-, фото- изображениям, что позволяет обнаруживать нежелательные состояния растений (болезни), которые могут служить сигналом для активизации процесса поиска решений в базе знаний.

Ключевые слова: вывод на основе прецедентов, принятие решений, нейросеть, архитектура нейросети, умная ферма.

1. Введение. Цифровизация сельского хозяйства и агропромышленного комплекса в целом с применением методов искусственного интеллекта стала одним из трендов развития отрасли в последние годы. Примерами того, как современное сельскохозяйственное предприятие становится сложным, высокотехнологическим комплексом с высоким уровнем автоматизации рабочих процессов могут служить городские фермы (контейнерные, вертикальные сити-фермы) [1 – 3], «умные» фермы и аквафермы (smart farms) [4 – 6]. Умные фермы стремятся к тому, чтобы стать полностью автономными, роботизированными предприятиями, которые при разведении сельскохозяйственных видов или пород животных не требуют участия человека [2]. Это не только существенно

облегчает данную производственную деятельность, но и снижает требования к квалификации специалистов и менеджеров, в ней участвующих. Ключевым в работе умных ферм становится организации сбора и использования данных, что позволяет не только контролировать и прогнозировать состояние производимой продукции и технологических систем, но и управлять в автоматическом режиме параметрами микроклимата, почвы, питания и т.п. для достижения желаемых результатов [5, 7]. Несмотря на широкое применение технологий мониторинга и анализа данных в работе таких высокотехнологических комплексов не исключается возникновение нештатных ситуаций, которые могут быть связаны как с болезнями растений или животных, так и с поломками оборудования, авариями. Подобные ситуации не возникают ежедневно, однако, они могут критически повлиять на работу предприятия и потому требуют оперативного, грамотного принятия решений. В то же время относительная редкость нештатных ситуаций обуславливает отсутствие, как правило, необходимого опыта и знаний у работников или менеджеров сельскохозяйственного предприятия, а специалисты-эксперты в нужной области не всегда являются доступными.

В этой связи перспективы дальнейшей интеллектуализации сельскохозяйственного производства и умных ферм, в частности, сегодня связываются с развитием технологий систем, применяемых для обнаружения, распознавания сложных производственных ситуаций и поиска эффективных решений в этих ситуациях. Так, для обнаружения и распознавания болезней растений свою эффективность уже показали искусственные нейросети, в частности, глубокие сверточные сети, которые работают в составе систем видеонаблюдения [8 – 11]. Однако, обнаруживая проблему, такие нейросети не предлагают ответов на вопросы «Что и как делать?», чтобы устранить эту проблему. На следующих этапах развития факт обнаружения и классификации болезни или любой другой проблемной ситуации требуется дополнить выводом рекомендованных или обязательных программ действий, которые нужно выполнить в этой ситуации.

Сегодня имеется опыт создания интеллектуальных систем, в том числе, в агропромышленном производстве и смежных областях, которые способны не только обнаруживать проблемные ситуации, но и предлагать для них рациональные решения. Так, в работе [12] приводится пример разработки системы, которая на основе экспертного опыта выводит рекомендации по выполнению защитных действий для источников воды. В [13] на основе анализа ситуаций и рассуждений по прецедентам предлагаются решения по ирригационной деятельности на

виноградниках, в [14] этот же подход используется для принятия решений в чрезвычайных экологических ситуациях, в статье [15] исследуются вопросы вывода решений для организации производства аквакультуры.

В этих исследованиях для вывода решений в проблемных ситуациях применяется известный в области искусственного интеллекта метод вывода решений на основе рассуждений по прецедентам (Case-based reasoning, CBR) [16]. Этот метод показал свою эффективность во многих предметных областях, когда необходимо принятие решений в условиях слабой формализации критериев и условий выбора, не позволяющих использовать строгие математические модели и методы оптимизации.

В CBR-системе используется интуитивно понятная идея о том, что, если имеется положительный опыт разрешения некоторой проблемной ситуации, то при возникновении подобной ситуации в дальнейшем мы также можем воспользоваться этот опыт для получения положительного результата. Тогда наличие достаточно большой по объему базы знаний (БЗ), где будут храниться прецеденты – пары <Ситуация-Решение>, позволит при возникновении проблемной ситуации подобрать для нее решение, сравнивая эту проблемную ситуацию с теми, которые есть в БЗ.

Важным преимуществом такого подхода является скорость вывода решений (т.к. производится выбор из готовых вариантов, а не разрабатываются новые), возможность поиска решений в условиях слабой формализации и неопределенности, а также потенциально высокое, экспертное качество принимаемых решений (за счет обеспечения такого качества решений в БЗ).

В то же время простая на первый взгляд идея CBR для реализации ее в прикладных системах требует выполнения ряда нетривиальных задач, к которым относятся, прежде всего, задачи формализации представления ситуаций и разработки на этой основе способов сравнения и отбора ситуаций в БЗ.

В данной работе предлагается решение этих задач с учетом возможностей их применения при создании ситуационных систем вывода решений, как одного из новых сервисов умной фермы [17]. Сначала в статье описывается способ математического представления сложных ситуаций, далее исследуются обучаемые нейросетевые модели схожести, на основе чего предлагается ансамблевая нейросетевая архитектура для сравнения и отбора ситуаций в процессах ситуационного вывода решений.

1.1. Методы. В CBR-системе прецедент образуется парой $\langle \text{Sit}, \text{Sol} \rangle$, где Sit является формализованным представлением известной из прошлого опыта ситуации, а Sol представляет решение, которое предлагается в данной ситуации. В зависимости от назначения CBR-системы ее решения могут содержать в себе команды для управления режимами технологического оборудования, целевые значения контролируемых параметров, программы действий персонала для устранения аварийных ситуаций, рекомендации, инструкции и др.

Если в наблюдаемой системе возникает проблемная ситуация Sit_{act} , требующая своего решения, оно ищется в БЗ путем сравнения Sit_{act} с ситуациями из базы знаний, выбора наиболее похожей ситуации Sit^* и вывода того решения Sol^* , которое входит в пару $\langle \text{Sit}^*, \text{Sol}^* \rangle$. Для определения степени похожести ситуаций некоторым образом задается функция $\text{Sim}(\text{Sit}_{\text{act}}, \text{Sit}_z)$, которая позволяет не просто зафиксировать факт похожести двух ситуаций Sit_{act} и Sit_z , но и количественно оценить степень этой похожести с тем, чтобы обеспечить обоснованный выбор на множестве ситуаций в БЗ, т.е.:

$$\text{Sit}^* = \text{argmax Sim}(\text{Sit}_{\text{act}}, \text{Sit}_z), \quad (1)$$

где z – индекс множества ситуаций в базе знаний, пробегающий значения от 1 до общего числа прецедентов, имеющих в БЗ на данный момент.

За счет этого появляется возможность вместо вывода типовых решений, основанного на распознавании класса входных ситуаций, находить конкретные и детальные решения, которые будут наибольшим образом подходить именно к данной проблемной ситуации Sit_{act} .

Условие выбора (1) может дополняться ограничениями, среди них особое место занимает ограничение на минимально допустимое значение $\text{Sim}(\cdot) \geq \text{Th}$, где Th – пороговое значение, которое ограничивает возможность применения найденного Sol^* . В случае, если $\text{Sim}(\text{Sit}_{\text{act}}, \text{Sit}^*) < \text{Th}$, найденное решение Sol^* не рекомендуется для непосредственного применения, но оно может служить основой для разработки нового решения Sol_{act} . Этот процесс называется адаптацией решений [18], по результатам которого в базу знаний (после соответствующей оценки найденного решения) добавляется новая пара $\langle \text{Sit}_{\text{act}}, \text{Sol}_{\text{act}} \rangle$.

Таким образом, в процессе эксплуатации CBR-системы обеспечивается пополнение ее базы знаний. Вопросы пополнения прецедентной БЗ, актуализации прецедентов и обслуживания объемных баз знаний составляют одно из направлений современных исследований

в данной области [18–20]. Но основными при разработке прецедентных систем являются задачи формализации прецедентов, в частности, представления ситуаций и связанные с ними задачи сравнения и оценки схожести ситуаций.

Наиболее очевидным способом представления ситуаций является представление их точками в многомерном пространстве параметров, которые собираются и оцениваются в наблюдаемой системе.

В этом случае оценка схожести Sim может быть определена с помощью метрик расстояния в этом пространстве, обзор которых приведен, например, в [21–23]. Однако, задачи представления и оценки схожести ситуаций при таком подходе усложняются с увеличением числа контролируемых параметров, при появлении наряду с количественными еще и качественных, а также неточных или неполных данных. Проблема усугубляется в сложных системах, когда в описании ситуаций для принятия решений необходимо учитывать состояния значительного числа неоднородных объектов и отношений между ними, которые могут описываться данными разной природы и разных форм представления.

В подобных условиях могут использоваться локальные метрики схожести [24], что говорит о появлении векторного критерия выбора:

$$Sit^* = \operatorname{argmax} \{Sim_1(Sit_{act}, Sit_z), \dots, Sim_k(Sit_{act}, Sit_z), \dots, Sim_N(Sit_{act}, Sit_z)\}. \quad (2)$$

Положительно то, что в (2) каждая из локальных функций схожести Sim_k может быть вычислена по-своему и на своей части данных. В то же время остается проблема дальнейшего выбора, который на практике сведется или к поиску парето-оптимальных решений, т.е. отбору нескольких несравнимых вариантов решений из БЗ, или к выбору способа агрегирования, т.е. перевода вектора в итоговую агрегированную Sim с дальнейшим выбором по (1).

В первом случае мы не избавляем пользователя (который может не обладать необходимой квалификацией и опытом) от проблемы выбора. Во втором случае с помощью экспертов необходима разработка модели компромисса между локальными метриками (например, на основе введения коэффициентов относительной важности), что может стать трудоемким. Кроме того, в сложных системах модель компромисса может оказаться не постоянной, т.е. веса относительной важности сходства по той или иной группе параметров Sim_k могут меняться в зависимости от состояний объектов и связей между ними. В

подобных случаях перспективным является использование обучаемой функции Sim и, в частности, применение нейросетевых моделей [15, 24, 25], с помощью которых функция схожести может быть представлена в виде:

$$\text{Sim} = f_m(W_m, \dots, f_1(W_1, X_{\text{in}})), \quad (3)$$

где X_{in} – вектор входных данных нейросети, который содержит в себе информацию о сравниваемых ситуациях;

W_m, \dots, W_1 – настраиваемые в процессе обучения веса межнейронных связей на слоях от 1 до m , причем для всех слоев $W \in R^{T \times V}$, T и V – размерности соответственно выходного и входного векторов на данном слое нейросети;

f_m, \dots, f_1 – функции активации на выходе нейронов на слоях от 1 до m .

При обучении на примерах похожих и непохожих пар ситуаций подбираются веса нейросетевой модели (3) так, чтобы она могла вычислять оценку схожести Sim (.) для новых, в том числе, неизвестных ей ранее ситуаций. Качество модели оценивается с помощью специальных метрик при использовании валидационных наборов данных, которые не участвовали в обучении. Подбор архитектуры (количество слоев, размерность векторов, виды активационных функций и т.п.) осуществляется экспериментально.

Далее в статье разрабатываются формализованные математические представления сложного технологического объекта умной фермы и ситуаций, которые обеспечивают возможности использования нейросетевых моделей, описываются примеры представления ситуаций, возникающие на технологическом объекте умной фермы. После этого проводятся экспериментальные исследования нейросетевых моделей и формулируются выводы для организации процесса поиска решений.

1.2. Формализация представлений объекта и ситуаций. Для формализации представления ситуации, которая может возникать в процессе работы умной фермы, далее будем использовать предложенное авторами ранее обобщенное представление сложного технологического объекта (СТО) [26]. Будем использовать абстрактный СТО, который состоит из N -го числа элементов и представляется следующим кортежем множеств:

$$\text{СТО} = \langle O, S, P, D \rangle,$$

где $O = \{ O_i \mid \forall i \in [1; N] \}$ – множество элементов сложного технологического объекта, N – число элементов сложного объекта. Под элементом понимается в данном случае любая из технологических подсистем умной фермы, собственно производимая продукция, объекты операционного окружения (при необходимости учитывать их состояние при принятии решений), а также отношения между ними. Каждый i -й элемент может находиться в некотором состоянии (например, «исправен» или «неисправен»). Кроме состояний элементы СТО могут характеризоваться дополнительными параметрами, которые ниже названы оцениваемыми;

$S = \{ S_i \mid \forall i \in [1; N] \}$ и $S_i = \{ S_{ij} \mid \forall j \in [1; N_{s_i}] \}$ – множество состояний i -го элемента СТО, N_{s_i} – число возможных состояний i -го элемента;

$P = \{ P_k \mid \forall k \in [1; N_p] \}$, $k \in \{ K_i \}$ – множество оцениваемых параметров, K_i – подмножество индексов, имеющих отношение к i -му элементу СТО, N_p – число оцениваемых параметров;

$D = \{ D_k \mid \forall k \in [1; N_p] \}$, D_k – упорядоченное множество категориальных значений k -го параметра.

Категории параметра могут задаваться лингвистическими значениями (например, параметр «Температура» может иметь область значений «Низкая», «Средняя», «Высокая»), интервалами на шкале значений оцениваемого параметра, логическими значениями (False, True) и иным способом задания перечислимых типов данных.

Каждому i -му элементу в текущий момент времени можно сопоставить вектор состояний с размерностью N_{s_i} , компоненты которого принимают значение 1 (элемент находится в j -м состоянии) или 0 (элемент не находится в данном состоянии). Аналогичным образом каждый k -й оцениваемый параметр P_k тоже представляется вектором из 0 и 1 размерность которого равна $|D_k|$. С учетом этой схожести далее для упрощения введем один универсальный оценочный вектор (состояний и параметров) $S^{\alpha\beta}$, компоненты которого могут принимать значения 1 или 0, а индекс β будет означать все множество индексов в множествах состояний и множествах категориальных значений. Набор таких векторов, которым описывается все множество элементов сложного объекта, составляет мультивектор $S^{\alpha\beta}$, где индекс α обозначает все множество индексов $r \in [1; (N + N_p)]$. Иначе говоря, α и β в $S^{\alpha\beta}$ представляют собой оси координат, где первая обозначает элементы или параметры, а вторая – их возможные состояния или значения.

Определение. Ситуацией на СТО называется такое положение дел, которое характеризуется совокупностью состояний элементов и категориальных значений оцениваемых параметров сложного объекта.

С учетом этого мультивектор $S^{\alpha\beta}$ есть формальное представление ситуации, т.е. $Sit \Leftrightarrow S^{\alpha\beta}$. Отметим, что $S^{\alpha\beta}$ не является матрицей, однако, он может быть записан в виде таблицы значений, где столбцы будут означать элементы и оцениваемые параметры, а строки соответствовать их состояниям или категориальным значениям, как это далее показано в таблице 1.

Конкатенация строк такой таблицы образует внутреннее (встроенное) представление ситуации – эмбединг ситуации, который будет использован для формирования входа нейросетевых моделей (раздел 2.1). Чтобы не вводить дополнительных обозначений, далее будем полагать, что мультивектор $S^{\alpha\beta}$ может быть представлен как в виде двумерной таблицы, так и в виде одномерного массива, получаемого конкатенацией строк этой таблицы, или с помощью иной формы представления при сохранении возможности обращения к любому из компонентов мультивектора с помощью указания значений индексов по осям α и β .

2.1. Описание объекта. Рассматриваемая умная ферма представляет собой автоматизированную систему выращивания растений на гидропонике [3]. Она осуществляет контроль управляемых параметров (температуру, влажность, освещенность, уровень CO_2 , количество и состав микроэлементов и рН в питательном растворе и др.) и регулирование режимов работы технологического оборудования для создания условий, необходимых для выращиваемых культур. За счет этого обеспечивается эффективность и качество роста растений, уменьшается зависимость от погодных условий и опыта агронома.

В целях представления и анализа ситуаций элементы СТО и оцениваемые параметры умной фермы собраны в следующие группы – компоненты комплексной ситуации: «Микроклимат», «Питание», «Освещение», «Растения». В некоторой ситуации каждая группа характеризуется состояниями входящих в нее элементов и значениями оцениваемых параметров. Например, подсистема «Микроклимат» описывается параметрами «Температура», «Влажность», «Уровень CO_2 » и элементами «Датчик температуры», «Датчик влажности», «Датчик CO_2 ». Датчики температуры, влажности, CO_2 могут быть в одном из двух состояний «Исправен» или «Неисправен», а оцениваемые параметры принимают значения из списка [«Ниже порога», «Минимум», «Оптимум», «Максимум», «Выше порога»], где первое и последнее значение являются недопустимыми.

В таблице 1 представлен пример комплексной ситуации, здесь единица в столбце соответствует тому состоянию, в котором находится данный элемент или тому значению, которое принимает данный параметр.

Таблица 1. Представление ситуации на умной ферме

Sit	Элементы и параметры	исправен	неисправен	ниже порога	минимум	оптимум	максимум	выше порога
«Микроклимат»	Температура			0	0	0	1	0
	Датчик температуры	1	0					
	Влажность			0	0	1	0	0
	Датчик влажности	1	0					
	Уровень CO2			0	1	0	0	0
	Датчик CO2	1	0					
«Полив»	Ph (кислотность раствора)			0	0	1	0	0
	pH-метр	1	0					
	ЕС по элементный (N P K+ микромакроэлементы)			0	0	0	1	0
	датчик электропроводности	1	0					
	Температура раствора			0	0	1	0	0
	Датчик температуры	1	0					
	Интенсивность полива			0	0	1	0	0
Таймер полива	1	0						
«Освещение»	Освещение	1	0					
	Мощность освещения			0	0	1	0	0
	Периодичность освещения			0	0	0	1	0
					Низкое	Среднее	Высокое	Отсутствует
«Растения»	Увядание				1	0	0	0
	Пожелтение				0	0	1	0
	Ожоги				0	0	1	0

Как было сказано выше, эмбединг данной ситуации формируется путем конкатенации строк таблицы, для примера по данным таблицы 1 имеем следующее внутренне представление ситуации:

$$S^{a\beta} = (0,0,0,1,0,1,0,0,0,1,0,0,1,0,0,1,0,0,0,1,0,0,0,1,0,0,1,0,0,0,1,0,1,0,0,0,1,0,0,1,0,0,1,0,0,0,0,1,0,0,0,1,0,0,0,1,0,0,1,0,0,0,0,1,0,1,0,0,0,0,1,0,0,0,0,1,0,0,0,1,0).$$

Полученный вектор является внутренним представлением ситуации, который будет использоваться на входе системы вычисления схожести и отбора ситуаций из базы знаний.

2.2. Описание набора данных. Для создания набора обучающих данных с помощью экспертов были выделены следующие три характерные ситуации:

– ситуация № 1, она характеризуется выходом из строя таймера системы полива (таблица 2). Состояние этого элемента в таблице принимает значение «Неисправен» При этом наблюдается увядание растений, а также средней степени ожоги и пожелтение. В таблице это показано так: оцениваемый параметр «Увядание» в группе «Растения» имеет значение «Максимум», чему соответствует вектор 0010. Аналогичным образом параметрам «Пожелтение» и «Ожоги» ставятся в соответствие векторы 0100;

– ситуация № 2, которая отражает состояния элементов по прошествию суток после выхода из строя кондиционера (кондиционер не рассматривается как часть объекта в данном эксперименте). При этом наблюдается повышенная температура, увядание растений, сниженный уровень концентрации CO₂ в воздухе;

– ситуация № 3, она характеризуется выходом из строя таймера выключения освещения. При этом наблюдается повышенная температура, пожелтения и увядание растений.

Ситуации № 2 и № 3 представляются аналогичными таблицами, как и таблица 1 для ситуации № 1, где устанавливаются единицы напротив соответствующих состояний элементов или значений оцениваемых параметров.

На основании этих примеров ситуаций далее был сгенерирован набор данных объемом 1700 пар ситуаций с оцененной схожестью по алгоритмам преобразования примеров, представленным в работе [27]. Для этого сначала экспертом была оценена относительная важность каждого элемента в сложившейся ситуации по шкале от 0 до 10. Из этих оценок были получены весовые коэффициенты значимости для формулы аддитивной свертки, которая использовалась при разметке обучающего набора данных.

Таблица 2. Ситуация № 1 с неисправным таймером полива

Sit _i	Элементы и параметры	Состояние						
		исправен	неисправен	ниже порога	минимум	оптимум	максимум	выше порога
«Микроклимат»	Температура			0	0	1	0	0
	Датчик температуры	1	0					
	Влажность			0	0	1	0	0
	Датчик влажности	1	0					
	Уровень CO ₂			0	0	1	0	0
	Датчик CO ₂	1	0					
«Полив»	Ph (кислотность раствора)			0	1	0	0	0
	pH-метр	1	0					
	ЕС по элементный (N P K+ микромакроэлементы)			0	1	0	0	0
	Датчик электропроводности	1	0					
	Температура раствора			0	0	1	0	0
	Датчик температуры	1	0					
	Интенсивность полива			1	0	0	0	0
	Таймер полива	0	1					
«Освещение»	Освещение	1	0					
	Мощность освещения			0	0	1	0	0
	Периодичность освещения			0	0	1	0	0
					Низкое	Среднее	Высокое	Отсутствует
«Растения»	Увядание				0	0	1	0
	Пожелтение				0	1	0	0
	Ожоги				0	1	0	0

Все вектора ситуаций в обучающем наборе данных являются результатом one-hot кодирования (вектора, соответствующие своим элементам (параметрам), принимают значение 0 или 1, при этом только один из них равен 1).

2.3. Валидационные наборы данных. Для проверки работоспособности обученных моделей дополнительно к обучающим

данным были разработаны валидационные наборы. Было подготовлено 3 валидационных набора данных (1В, 2В, 3В), позволяющих оценить способность нейросетевой модели:

- отбирать схожие ситуации;
- ранжировать схожие ситуации по степени схожести;
- работать в условиях нечеткой классификации состояний, когда компоненты вектора представления ситуаций принимают значения в интервале от 0 до 1.

Валидационные наборы содержат пары ситуаций с оцененной экспертом схожестью, отличные от пар ситуаций из обучающего набора.

Наборы 1В и 2В содержат по 15 пар ситуаций, где одна ситуация сравнивается с 15 другими разной схожести (значения схожести Sim меняются в интервале от 0,50 до 0,95).

Валидационный набор 3В содержит 10 пар ситуаций. Он имитирует возникновение нежелательной ситуации с неточным определением состояний некоторых элементов, т.е. когда компоненты вектора ситуации принимают значения в интервале [0;1]. Такая ситуация здесь названа нечеткой. Она иллюстрирует случай, при котором специалист, эксплуатирующий умную ферму, в силу недостатка данных (из-за неисправности оборудования) или недостатка знаний и опыта не может сделать точные выводы о значениях тех или иных параметров в текущей ситуации. Предполагается, что и в таком случае СВР-система должна уметь находить в базе знаний похожие ситуации с тем, чтобы предложить необходимое решение.

Примером нечеткой ситуации является ситуация, представленная в таблице 3. Она характеризуется неисправностью датчика регулятора кислотности раствора рН. Так как с датчика измерения рН раствора не поступает данные, то точно оценить кислотность невозможно. В силу этого используется нечеткое оценивание параметра Ph, когда при наблюдении за текущей ситуацией специалист умной фермы высказывает свои предположения относительно значения этого параметра. При этом он выставляет субъективную оценку вероятности (коэффициент уверенности) предполагаемого значения, которое принимает данный параметр в этой ситуации – в примере это значения «Ниже порога» и «Минимум» с оценками вероятности 0.4 и 0.6 соответственно. Аналогичным образом, в данной ситуации нечетко оцениваются значения параметров в группе «Растения». Когда при анализе состояния растений наблюдатель не может однозначно оценить параметры «Увядание», «Пожелтение», «Ожоги», он выставляет им значения списком [«Низкое», «Среднее», «Высокое»] с

соответствующими субъективными оценками вероятности этих значений.

Таблица 3. Пример ситуации с неточными параметрами

i_{k3}	Элементы и параметры	исправно	неисправно	ниже порога	минимум	оптимум	максимум	выше порога
«Микроклимат»	Температура			0	0	1	0	0
	Датчик температуры	1	0					
	Влажность			0	0	1	0	0
	Датчик влажности	1	0					
	Уровень CO ₂			0	0	1	0	0
	Датчик CO ₂	1	0					
«Полив»	Ph (кислотность раствора)			0.4	0.6	0	0	0
	pH-метр	0	1					
	ЕС по элементный (N P K+ микромакроэлементы)			0	0	1	0	0
	датчик электропроводности	1	0					
	Температура раствора			0	0	1	0	0
	Датчик температуры	1	0					
	Интенсивность полива			0	0	1	0	0
	Таймер полива	1	0					
«Освещение»	Освещение	1	0					
	Мощность освещения			0	0	1	0	0
	Периодичность включения освещения			0	0	1	0	0
					Низкое	Среднее	Высокое	Отсутствует
«Растения»	Увядание				0.4	0.6	0	0
	Пожелтение				0	0.6	0.4	0
	Ожоги				0	0.8	0.2	0

В нечеткой ситуации вместо one-hot кодирования векторов используется «мягкое», soft кодирование, при котором в любом из векторов могут присутствовать числа от нуля до единицы в разных позициях.

В экспериментах такая ситуация сравнивалась с 10 другими ситуациями, где состояния элементов и значения параметров были точно известны. Таким образом, проверялась гипотеза о применимости обученной нейросети для сравнения и отбора ситуаций в базе знаний, когда входная, текущая ситуация является нечеткой.

2.4. Описание метрик. Для оценки нейросетевых моделей использовались следующие метрики.

1) MAPE (Mean Absolute Percentage Error) – абсолютная средняя процентная ошибка [28] значения Sim, которая вычислялась по следующей формуле:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| * 100\%, \quad (4)$$

где n – количество оцениваемых Sim пар ситуаций, y_t – значение Sim из валидационного файла, \hat{y}_t – модельное значение полученного Sim.

2) nDCG@k (Normalized Discounted Commulative Gain для лучших k) – метрика для оценки верности ранжирования k ситуаций [29] лучших по величине Sim. Вычислялась по следующим формулам:

$$\text{NDCG}_k = \frac{\text{DCG}_k}{\text{IDCG}_k}, \quad (5)$$

$$\text{DCG}_k = \sum_{i=1}^k \frac{2^{\hat{r}_i} - 1}{\log_2(1+i)}, \quad (6)$$

где \hat{r}_i – оцененная релевантность результата на позиции i , IDCG $_k$ – значение DCG $_k$ при ранжировании по истинным значениям (рейтингам из валидационного набора), k – количество оцениваемых ситуаций, принято $k=6$.

3) Accuracy – метрика для оценки верности определения класса [30]. В нашем случае класс пар ситуаций «похож/непохож» при пороге $Sim > 0.75$. Вычислялась по следующей формуле:

$$Accuracy = \frac{TP+TN}{TP+TN+FN+FP}, \quad (7)$$

где TP – верные положительные (похож) классификации; TN – верные отрицательные (непохож) классификации; FP – неверные положительные (похож) классификации; FN – неверные отрицательные (непохож) классификации.

2.5. Результаты. В исследовании был проведен эксперимент по анализу производительности трех нейросетевых моделей для оценки схожести ситуаций и их комбинаций. Каждая модель оперирует входными данными, получаемыми из мультивекторов двух сравниваемых ситуаций.

За основу архитектуры модели взята архитектура полносвязной нейронной сети (рисунок 1).

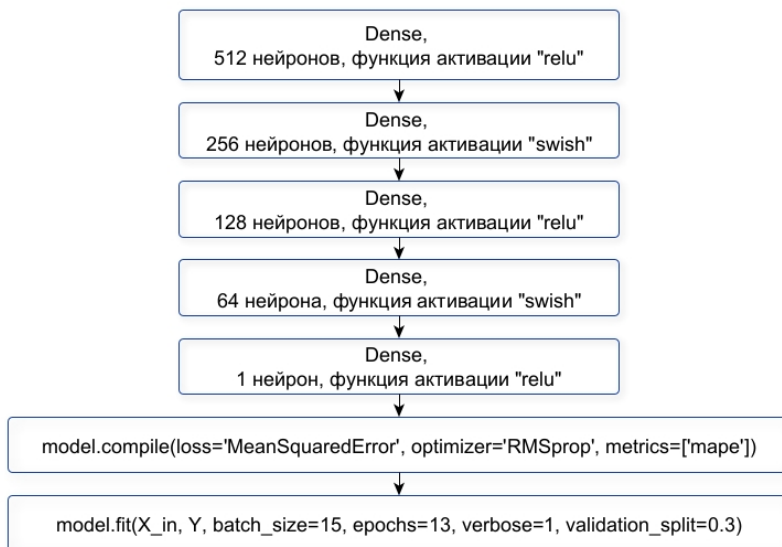


Рис. 1. Полносвязная нейронная сеть

Модель M1 на вход получает единый образ двух ситуаций X_{in} в виде конкатенации (concat) мультивекторов текущей ситуации S^{ab}_{act} и ситуации из базы знаний S^{ab}_z и преобразует его в оценку схожести этих ситуаций Sim:

$$X_{in} = \text{concat}(S^{ab}_{act}, S^{ab}_z),$$

$$M1: X_{in} \rightarrow \text{Sim} \in [0;1].$$

Этот способ формирования входного сигнала использован в одной из архитектур сиамских нейронных сетей, специально предназначенных для сравнения объектов [15].

Модель M2 на вход получает посимвольную разницу мультивекторов двух ситуаций:

$$X_{in} = |S^{ab}_{act} - S^{ab}_z|,$$

$$M2: X_{in} \rightarrow \text{Sim} \in [0;1].$$

Этот способ формирования входного сигнала был использован в работе [31]. Он позволяет сократить длину входного вектора в два раза по сравнению с тем, который используется в модели M1. Сокращение размерности входного вектора потенциально обладает положительным свойством, т.к. уменьшает количество комбинаций входных векторов, которые могут давать на выходе один и тот же результат вычислений.

Модель M3, которая на вход получает посимвольную сумму двух мультивекторов:

$$X_{in} = S_{act} + S_z,$$

$$M3: X_{in} \rightarrow \text{Sim} \in [0;1].$$

Здесь компоненты входного для модели вектора X_{in} принимают значения от 0 до 2, что интерпретируется следующим образом. Некоторый ij -й компонент входного вектора X_{in} принимает значение 2 в том случае, когда в обеих ситуациях i -й элемент находится в j -м состоянии, значение 0 – элемент не находится в этом состоянии ни в одной из ситуаций, значение 1 – i -й элемент находится в j -м состоянии в одной из сравниваемых ситуаций.

В работе [32] представлены результаты исследования предложенных моделей M1, M2, M3 для вычисления Sim. В этой статье мы приводим результаты дальнейших исследований, где в целях улучшения метрик качества рассматриваются ансамбли нейросетевых моделей.

Пример архитектуры ансамблевой модели приведен на рисунке 2, программная реализация выполнена на языке Python с использованием библиотек Keras, TensorFlow.

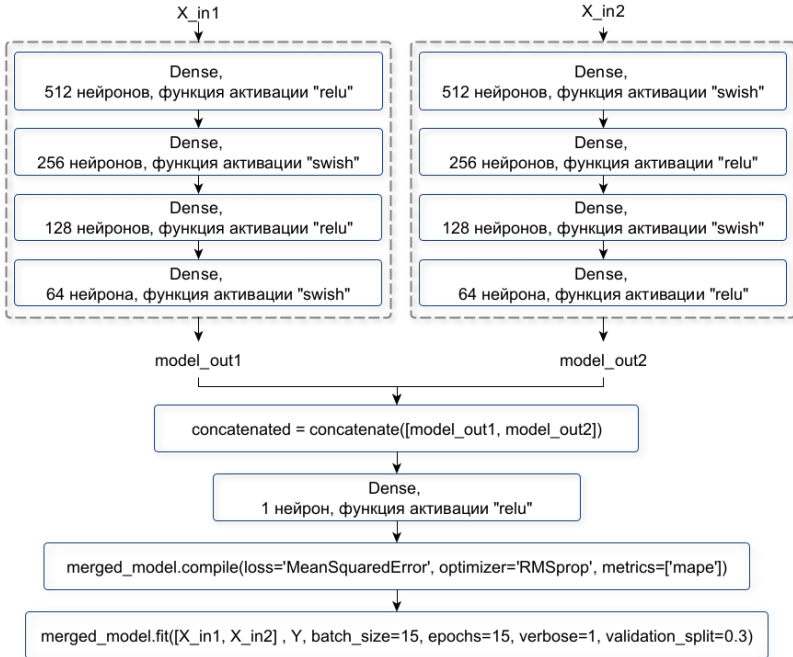


Рис. 2. Архитектура ансамблевой модели

Цикл обучения, валидации и анализа показателей производился 8 раз на одних и тех же данных для каждой модели в целях оценки стабильности показателей, что потенциально позволяет обеспечить стабильность работы на новых наборах данных.

В качестве альтернативы нейросетевым моделям рассмотрена модель агрегирования локальных метрик сходства (2) на основе аддитивной свертки с постоянными коэффициентами относительной важности, которые определяются путем экспертного опроса.

При этом формула (2) преобразуются в следующую:

$$Sim = \sum \alpha_k Sim_k, \quad (8)$$

где α_k – весовой коэффициент группы, определяемый экспертами, Sim_k – сходство k -й группы элементов СТО в двух сравниваемых ситуациях, определяемое по формуле:

$$Sim_k = \sum \beta_{ki} f_{ki},$$

где β_{ki} – коэффициент относительной важности i -го элемента (параметра) в k -й группе, принимающий значение в интервале от 0 до 1 при сумме всех коэффициентов в данной группе равной единице. Его значение, как и значение коэффициентов α , тоже определяется экспертным путем;

f_{ki} – показатель сходства i -го элемента (параметра) в k -й группе в сравниваемых ситуациях. Он принимает значение 1, когда элементы (параметры) в двух ситуациях имеют одинаковое состояние (значение) или ноль в противном случае.

Лучшие показатели метрик из восьми проведенных экспериментов с валидационными данными для отдельных моделей и их ансамблей представлены в таблице 4.

Таблица 4. Показатели метрик

№ П/П	Метрика Модель	Точная классификация состояний и оценка параметров (набор 1В, 2В)			Неточная классификация состояний и оценка параметров (набор 3В)		
		MAPE	nDCG@k	Accuracy	MAPE	nDCG@k	Accuracy
1	M1	14%	61%	92%	21%	68%	80%
2	M2	3.75%	96%	96%	12%	98%	100%
3	M3	13.40%	89%	92%	19%	78%	70%
4	Ансамбль: M2, M2	3.39%	100%	100%	9.8%	98%	100%
5	Ансамбль: M2, M2, M2	7.90%	95%	100%	12%	95%	100%
6	Четыре модели: M2, M3, M2, M2	3.48%	98.5%	100%	12%	95%	100%
7	Аддитивная свертка с постоянными коэффициентами важности	6%	92%	90%	14%	60%	90%

3. Обсуждение результатов экспериментов. Эксперименты показали, что ансамбль простых моделей может обеспечивать более качественные результаты по сравнению с отдельным их применением. На основе показателей метрик, представленных в таблице 4, можно сделать вывод о целесообразности применения в задачах сравнения ситуаций ансамбля простых моделей: M2, M2 (таблица 4). Архитектура этого ансамбля моделей показана на рисунке 2.

Данный ансамбль моделей показал лучшие (в смысле используемых метрик качества) результаты при решении задач отбора схожих ситуаций и ранжирования ситуаций по степени схожести, в том числе в условиях возникновения нечеткой ситуации.

Актуальность ранжирования возрастает с усложнением объекта (увеличением количества элементов), когда возрастает риск возникновения коллизий, т.е. случаев, при которых различие ситуаций по одним атрибутам или локальным метрикам может компенсироваться их сходством по другим атрибутам.

Аддитивная свертка при проверке на валидационном наборе, несмотря на близкие к нейросетевым моделям результаты, не показала результативность при решении задачи ранжирования, приравняв по схожести 5 ситуаций. Напротив, нейросетевая модель успешно разделила эти ситуации по уровню схожести, позволив построить ранжированную по Sim(.) последовательность, совпадающую с мнением эксперта, с помощью которого был сформирован валидационный набор.

Таким образом, эксперименты показали, что нейросетевые модели и их ансамбли, обучившись на примерах, могут быть использованы для поиска и отбора в базе знаний похожие ситуации, удовлетворяющие критериям (1)-(2). При условии наполнения БЗ прецедентами $\langle \text{Sit}, \text{Sol} \rangle$ найденная Sit^* позволяет предложить пользователю то решение Sol^* , которое ассоциировано с этой ситуацией и которое рекомендовано для таких ситуаций. Так, в рассмотренных примерах при возникновении ситуации с неисправным рН-метром (таблица 3) БЗ может содержать в себе решение, которое будет представлять собой программу действий (технологическую карту) по устранению неисправности оборудования и рекомендуемые действия для восстановления состояний растений.

4. Заключение. В статье рассмотрено использование CBR-метода с представлением ситуаций посредством векторов, которые содержат в себе информацию о состояниях элементов и значений оцениваемых параметров, применительно к задачам ситуационного вывода решений при эксплуатации умной фермы.

Умная ферма представлена как сложный технологический объект, состоящий из взаимосвязанных компонентов, которыми являются технологические подсистемы умной фермы, производимая продукция, объекты операционного окружения, а также отношения между ними. Для реализации алгоритмов ситуационного вывода решений на основе прецедентов предложено формализованное представление ситуации в виде мультивектора $S^{a\beta}$, что позволило

разработать ряд моделей обучаемой функции схожести Sim между ситуациями. Проведенные эксперименты показали работоспособность предложенных моделей, на основе чего разработана ансамблевая архитектура нейросети для сравнения ситуаций и их отбора из базы знаний в процессах вывода решений. Применение нейросетей для количественной оценки схожести ситуаций позволяет отказаться от трудоемких задач экспертного оценивания ситуаций, разработки критериев и алгоритмов их сравнения в сложных условиях, в том числе, при неточных данных для идентификации ситуации, при необходимости применения локальных метрик схожести и динамичности весов относительной важности этих метрик.

Для применения предлагаемого подхода и разработанных моделей важным становится вопрос идентификации ситуаций, что связано с классификацией состояний компонентов умной фермы по собираемым данным. Практический интерес представляет мониторинг состояния растений по их видео-, фото- изображениям [8], что позволяет обнаруживать нежелательные состояния растений (болезни), которые могут служить сигналом для активизации процесса поиска решений в базе знаний. Разработка классификаторов состояний растений и иных компонентов умной фермы для идентификации ситуаций и запуска процессов вывода решений является следующим этапом исследований авторов.

Результаты исследования могут найти применение для разработки баз знаний и систем поддержки принятия решений в сложных ситуациях, возникающих при эксплуатации умных ферм (неисправности оборудования, болезни растений, недостатки питания и др.). Можно ожидать, что применение подобных систем будет способствовать повышению оперативности и качества принимаемых решений, а также менять требования к компетенциям специалистов и обслуживающего персонала умной фермы, смещая их профиль в сторону цифровых технологий. При этом для обучения моделей и создания баз знаний потребуются и эксперты в «своей» предметной области – высококвалифицированные специалисты сельского хозяйства, чьи знания и опыт станут доступны для обеспечения работы многочисленных ферм.

Литература

1. Руткин Н.М., Лагуткин О.Ю., Лагуткина Л.Ю. Урбанизированное агропроизводство (сити-фермерство) как перспективное направление развития мирового агропроизводства и способ повышения продовольственной безопасности городов // Вестник астраханского государственного технического университета. серия: рыбное хозяйство. 2017. Т. 2017. № 4. С.95–108.

2. Сурай Н.М., Кудинова М.Г., Уварова Е.В., Жидких Е.И. Анализ развития цифровых технологий в «умных» фермах // *Инновации и инвестиции*. 2021. № 10. С. 184–188.
3. Martin M., Molin E. Environmental Assessment of an Urban Vertical Hydroponic Farming System in Sweden // *Sustainability*. 2019. vol. 11(15). no. 4124. DOI: 10.3390/su11154124.
4. Chiu M.-C., Yan W.-M., Bhat S.A., Huang N.-F. Development of smart aquaculture farm management system using IoT and AI-based surrogate models // *Journal of Agriculture and Food Research*. 2022. vol. 9. no. 100357. DOI: 10.1016/j.jafr.2022.100357.
5. Devapal D. Smart Agro Farm Solar Powered Soil and Weather Monitoring System for Farmers // *Proceedings of International Multi-conference on Computing, Communication, Electrical & Nanotechnology, I2CN-2K19*. 2020. pp. 1843–1854.
6. He L., Fu L., Fang W., Sun X., Suo R., Li G., Zhao G., Yang R., Li R. IoT-based urban agriculture container farm design and implementation for localized produce supply // *Computers and Electronics in Agriculture*. 2022. vol. 203. no. 107445. DOI: 10.1016/j.compag.2022.107445.
7. Klaina H., Gueembe I.P., Lopez-Iturri P., Campo-Bescós M.A., Azpilicueta L., Aghzout O., Alejos A.V., Falcone F. Analysis of low power wide area network wireless technologies in smart agriculture for large-scale farm monitoring and tractor communications // *Measurement*. 2022. vol. 187(5). no. 110231. DOI: 10.1016/j.measurement.2021.110231.
8. Махмудул Хасан А., Мд Ракиб Ул Ислам Р., Авинаш К. Классификация болезней листьев яблони с использованием набора данных изображений: подход многослойной сверточной нейронной сети // *Информатика и автоматизация*. 2022. Т. 21. № 4. С. 710–728. DOI: 10.15622/ia.21.4.3
9. Moreira R., Moreira L.F.R., Munhoz P.L.A., Lopes E.A., Ruas R.A.A. AgroLens: A low-cost and green-friendly Smart Farm Architecture to support real-time leaf disease diagnostics // *Internet of Things*. 2022. vol. 19. no. 100570. DOI: 10.1016/j.iot.2022.100570.
10. Hu W.-C., Chen L.-B., Huang B.-K., Lin H.-M. A Computer Vision-Based Intelligent Fish Feeding System Using Deep Learning Techniques for Aquaculture // *IEEE Sensors Journal*. 2022. vol. 22. no. 7. pp. 7185–7194. DOI: 10.1109/JSEN.2022.3151777.
11. Cho S., Kim T., Jung D.-H., Park S.H., Na Y., Ihn Y.S., Kim K.G. Plant growth information measurement based on object detection and image fusion using a smart farm robot // *Computers and Electronics in Agriculture*. 2023. vol. 207. no. 107703. DOI: 10.1016/j.compag.2023.107703.
12. Cerutti J., Abi-Zeid I., Lamontagne L., Lavoie R., Rodriguez-Pinzon M.J. A case-based reasoning tool to recommend drinking water source protection actions // *Journal of Environmental Management*. 2023. vol. 331. no. 117228. DOI: 10.1016/j.jenvman.2023.117228.
13. Zhai Z., Martínez J.F., Martínez N.L., Díaz V.H. Applying case-based reasoning and a learning-based adaptation strategy to irrigation scheduling in grape farming // *Computers and Electronics in Agriculture*. 2020. vol. 178. no. 105741. DOI: 10.1016/j.compag.2020.105741.
14. Wang D., Wan K., Ma W. Emergency decision-making model of environmental emergencies based on case-based reasoning method // *Journal of Environmental Management*. 2020. vol. 262(9). 110382. DOI: 10.1016/j.jenvman.2020.110382.
15. Mathisen B.M., Bach K., Aamodt A. Using extended siamese networks to provide decision support in aquaculture operations // *Applied Intelligence*. 2021. vol. 51(1). DOI: 10.1007/s10489-021-02251-3.

16. Aamodt A., Plaza E. Case-Based Reasoning: Foundational Issues, Methodological Variations, and System Approaches // *AI Communications*. 2001. vol. 7. pp. 39–59. DOI: 10.3233/AIC-1994-7104.
17. Скобелев П.О., Симонова Е.В., Будаев Д.В., Вошук Г.Ю., Ларюхин В.Б. Облачная интеллектуальная система SMART FARMING для управления точным земледелием // *Материалы конференции «Информационные технологии в управлении (ИТУ-2018)»* (г. Санкт-Петербург, 2–4 октября 2018 г.). Издательство: Концерн «Концерн «ЦНИИ «Электроприбор», 2018. С. 261–270.
18. Leake D., Ye X., Crandall D. Supporting Case-Based Reasoning with Neural Networks: An Illustration for Case Adaptation // *Proceedings of the AAAI 2021 Spring Symposium on Combining Machine Learning and Knowledge Engineering (AAAI-MAKE 2021)*. 2021. Available at: <https://proceedings.aaai-make.info/AAAI-MAKE-PROCEEDINGS-2021/paper1.pdf>. (accessed 26.05.2023).
19. Guo Y., Zhang B., Sun Y., Jiang K., Wu K. Machine learning based feature selection and knowledge reasoning for CBR system under big data // *Pattern Recognition*. 2021. vol. 112(6). no. 107805. DOI: 10.1016/j.patcog.2020.107805.
20. Smiti A., Elouedi Z. Dynamic maintenance case base using knowledge discovery techniques for case based reasoning systems // *Theoretical Computer Science*. 2020. vol. 817. pp 24–32. DOI: 10.1016/j.tcs.2019.06.026.
21. Liao T.W., Zhang Z., Mount C.R. Similarity measures for retrieval in case-based reasoning systems // *Applied Artificial Intelligence*. 1998. vol. 12(4). pp. 267–288. DOI: 10.1080/088395198117730.
22. Fan Z.-P., Li Y.-H., Wang X., Liu Y. Hybrid similarity measure for case retrieval in CBR and its application to emergency response towards gas explosion // *Expert Systems with Applications*. 2014. vol. 41(5). pp. 2526–2534. DOI: 10.1016/j.eswa.2013.09.051.
23. Oyelade O.N., Ezugwu A.E. A case-based reasoning framework for early detection and diagnosis of novel coronavirus // *Informatics in Medicine Unlocked*. 2020. vol. 20(6). no. 100395. DOI: 10.1016/j.imu.2020.100395.
24. Gabel T., Godehardt E. Top-down induction of similarity measures using similarity clouds. *International Conference on Case-Based Reasoning*. 2015. pp. 149–16. DOI: 10.1007/978-3-319-24586-7_11.
25. Mathisen B.M., Aamodt A., Bach K., Langseth H. Learning similarity measures from data // *Progress in Artificial Intelligence*. 2020. vol. 9. pp. 129–143. DOI: 10.1007/s13748-019-00201-2.
26. Glukhikh I., Glukhikh D. Case-Based Reasoning with an Artificial Neural Network for Decision Support in Situations at Complex Technological Objects of Urban Infrastructure // *Applied System Innovation*. 2021. vol. 4(73). 12 p. DOI: 10.3390/asi4040073.
27. Глухих И.Н., Глухих Д.И. Алгоритмы генерации обучающих множеств в системе с прецедентным выводом на основе ситуаций-примеров // *Программные продукты и системы*. 2022. Т. 35. № 4. С. 660–669.
28. Myttenaere A.D., Golden B., Grand B.L., Rossi F. Mean Absolute Percentage Error for regression models // *Neurocomputing*. 2016. vol. 192. pp. 38–48. DOI: 10.1016/j.neucom.2015.12.114.
29. Wang Y., Wang L., Li Y., He D., Liu T.-Y., Chen W. A Theoretical Analysis of NDCG Type Ranking Measures. *Computer Science*. 2013. 26 p. DOI: 10.48550/arXiv.1304.6480.
30. Taylor J.R. *An Introduction to Error Analysis: The Study of Uncertainties in Physical Measurements*, Second Edition, Paperback & Clothbound, 1997. 327 p.
31. Paulson P., Juell P. Using Reinforcement Learning for Similarity Assessment in Case-Based Systems // *IEEE Intelligent Systems*. 2003. vol. 18. no. 4. pp. 60–67. DOI: 10.1109/MIS.2003.1217629.

32. Glukhikh I., Chernysheva T., Glukhikh D. Neural Network Models for Situation Similarity Assessment in hybrid-CBR // *Journal of Intelligent & Fuzzy Systems*. 2023. vol. 44(15). pp. 1–14. DOI: 10.3233/JIFS-221335.

Глухих Игорь Николаевич — д-р техн. наук, профессор, заведующий кафедрой, кафедра информационных систем, Институт математики и компьютерных наук (ИМиКН); научный руководитель центра системного инжиниринга, передовая инженерная школа, Тюменский государственный университет (ТюмГУ). Область научных интересов: интеллектуальные системы поддержки принятия решений, базы знаний, вывод на основе прецедентов, нейросети в принятии решений. Число научных публикаций — 180. i.n.glukhikh@utmn.ru; улица Володарского, 6, 625003, Тюмень, Россия; р.т.: +7(932)320-0036.

Прохошин Алексей Сергеевич — магистрант, руководитель проекта, лаборатория сельскохозяйственной микологии и биологической защиты растений института экологической и сельскохозяйственной биологии (x-bio), Тюменский государственный университет (ТюмГУ). Область научных интересов: интеллектуальные системы фитосанитарного мониторинга, системы автоматизированного выращивания растений в контролируемых условиях на малообъемной гидропонике, нейросети распознавания заболеваний и идентификации вредителей. Число научных публикаций — 5. a.s.prokhoshin@utmn.ru; улица Володарского, 6, 625003, Тюмень, Россия; р.т.: +7(932)320-0230.

Глухих Дмитрий Игоревич — аспирант, ассистент, кафедра информационных систем, Тюменский государственный университет (ТюмГУ). Область научных интересов: интеллектуальные системы поддержки принятия решений, базы знаний, вывод на основе прецедентов, нейросети в принятии решений, инженерно-технические и информационные автоматизированные системы мониторинга технических систем. Число научных публикаций — 25. gluhihdmitry@gmail.com; улица Володарского, 6, 625003, Тюмень, Россия; р.т.: +7(932)320-0036.

I. GLUKHIKH, A. PROKHOSHIN, D. GLUKHIKH
COMPARISON AND RETRIEVAL OF SITUATIONS IN THE CASE-BASED REASONING SYSTEM FOR SMART-FARM

Glukhikh I., Prokhoshin A., Glukhikh D. Comparison and Retrieval of Situations in the Case-Based Reasoning System for Smart-Farm.

Abstract. The trend of development of smart farms is aimed at their becoming fully autonomous, robotic enterprises. The prospects for the intellectualization of agricultural production and smart farms, in particular, today are associated with the development of technology systems used to detect, recognize complex production situations and search for effective solutions in these situations. The article presents the concept of such a decision support system on smart farms using the method of decision support based on case-based reasoning - CBR system. Its implementation requires a number of non-trivial tasks, which include, first of all, the tasks of formalizing the presentation of situations and creating methods for comparing and retrieving situations from the KB on this basis. In this study, a smart farm is presented as a complex technological object consisting of interrelated components, which are the technological subsystems of a smart farm, the products produced, the objects of the operational environment, as well as the relationships between them. To implement algorithms for situational decision-making based on precedents, a formalized representation of the situation in the form of a multivector is proposed. This allowed us to develop a number of models of the trained similarity function between situations. The conducted experiments have shown the operability of the proposed models, on the basis of which ensemble architecture of a neural network has been developed for comparing situations and selecting them from the knowledge base in decision-making processes. Of practical interest is monitoring the condition of plants by their video and photo images, which allows detecting undesirable plant conditions (diseases), which can serve as a signal to activate the process of searching for solutions in the knowledge base.

Keywords: case-based reasoning, decision making, neural network, neural network architecture, smart farm.

References

1. Rutkin N.M., Lagutkin O.Ju., Lagutkina L.Ju. [Urbanized agricultural production (city farming) as a promising direction for the development of international agricultural production and a way to ensure the food security of cities]. *Vestnik astrahanskogo gosudarstvennogo tehnikeskogo universiteta. serija: rybnoe hozjajstvo – Bulletin of the Astrakhan State Technical University. Series: fisheries.* 2017. vol. 2017. no. 4. pp. 95–108. (In Russ.).
2. Suraj N.M., Kudinova M.G., Uvarova E.V., Zhidkih E.I. [Analysis of the development of digital technologies in smart farms]. *Innovacii i investicii – Innovation and investment.* 2021. no. 10. pp.184–188. (In Russ.).
3. Martin M., Molin E. Environmental Assessment of an Urban Vertical Hydroponic Farming System in Sweden. *Sustainability.* 2019. vol. 11(15). no. 4124. DOI: 10.3390/su11154124.
4. Chiu M.-C., Yan W.-M., Bhat S.A., Huang N.-F. Development of smart aquaculture farm management system using IoT and AI-based surrogate models. *Journal of Agriculture and Food Research.* 2022. vol. 9. no. 100357. DOI: 10.1016/j.jafr.2022.100357.

5. Devapal D. Smart Agro Farm Solar Powered Soil and Weather Monitoring System for Farmers. Proceedings of International Multi-conference on Computing, Communication, Electrical & Nanotechnology, I2CN-2K19. 2020. pp. 1843–1854.
6. He L., Fu L., Fang W., Sun X., Suo R., Li G., Zhao G., Yang R., Li R. IoT-based urban agriculture container farm design and implementation for localized produce supply. *Computers and Electronics in Agriculture*. 2022. vol. 203. no. 107445. DOI: 10.1016/j.compag.2022.107445.
7. Klaina H., Guembe I.P., Lopez-Iturri P., Campo-Bescós M.A., Azpilicueta L., Aghzout O., Alejos A.V., Falcone F. Analysis of low power wide area network wireless technologies in smart agriculture for large-scale farm monitoring and tractor communications. *Measurement*. 2022. vol. 187(5). no. 110231. DOI: 10.1016/j.measurement.2021.110231.
8. Mahmudul Hasan A., Md Rakib Ul Islam R., Avinash K. [Apple Leaf Disease Classification Using Image Dataset: A Multilayer Convolutional Neural Network Approach]. *Informatika i avtomatizacija – Informatics and Automation*. 2022. vol. 21. no. 4. pp. 710–728. DOI: 10.15622/ia.21.4.3. (In Russ.).
9. Moreira R., Moreira L.F.R., Munhoz P.L.A., Lopes E.A., Ruas R.A.A. AgroLens: A low-cost and green-friendly Smart Farm Architecture to support real-time leaf disease diagnostics. *Internet of Things*. 2022. vol. 19. no. 100570. DOI: 10.1016/j.iot.2022.100570.
10. Hu W.-C., Chen L.-B., Huang B.-K., Lin H.-M. A Computer Vision-Based Intelligent Fish Feeding System Using Deep Learning Techniques for Aquaculture. *IEEE Sensors Journal*. 2022. vol. 22. no. 7. pp. 7185–7194. DOI: 10.1109/JSEN.2022.3151777.
11. Cho S., Kim T., Jung D.-H., Park S.H., Na Y., Ihn Y.S., Kim K.G. Plant growth information measurement based on object detection and image fusion using a smart farm robot. *Computers and Electronics in Agriculture*. 2023. vol. 207. no. 107703. DOI: 10.1016/j.compag.2023.107703.
12. Cerutti J., Abi-Zeid I., Lamontagne L., Lavoie R., Rodriguez-Pinzon M.J. A case-based reasoning tool to recommend drinking water source protection actions. *Journal of Environmental Management*. 2023. vol. 331. no. 117228. DOI: 10.1016/j.jenvman.2023.117228.
13. Zhai Z., Martínez J.F., Martínez N.L., Díaz V.H. Applying case-based reasoning and a learning-based adaptation strategy to irrigation scheduling in grape farming. *Computers and Electronics in Agriculture*. 2020. vol. 178. no. 105741. DOI: 10.1016/j.compag.2020.105741.
14. Wang D., Wan K., Ma W. Emergency decision-making model of environmental emergencies based on case-based reasoning method. *Journal of Environmental Management*. 2020. vol. 262(9). 110382. DOI: 10.1016/j.jenvman.2020.110382.
15. Mathisen B.M., Bach K., Aamodt A. Using extended siamese networks to provide decision support in aquaculture operations. *Applied Intelligence*. 2021. vol. 51(1). DOI: 10.1007/s10489-021-02251-3.
16. Aamodt A., Plaza E. Case-Based Reasoning: Foundational Issues, Methodological Variations, and System Approaches. *AI Communications*. 2001. vol. 7. pp. 39–59. DOI: 10.3233/AIC-1994-7104.
17. Skobelev P.O., Simonova E.V., Budaev D.V., Voshhuk G.Ju., Larjuhin V.B. [Cloud intelligent system SMART FARMING for precision farming management]. *Materialy konferencii «Informacionnye tehnologii v upravlenii (ITU-2018)»* [Materials of the conference "Information Technologies in Management (ITU-2018)"]. St. Petersburg, Concern "Concern" Central Research Institute "Elektropribor", 2018. pp. 261–270.
18. Leake D., Ye X., Crandall D. Supporting Case-Based Reasoning with Neural Networks: An Illustration for Case Adaptation. Proceedings of the AAAI 2021 Spring Symposium on Combining Machine Learning and Knowledge Engineering (AAAI-MAKE 2021).

2021. Available at: <https://proceedings.aaai-make.info/AAAI-MAKE-PROCEEDINGS-2021/paper1.pdf> (accessed 26.05.2023).
19. Guo Y., Zhang B., Sun Y., Jiang K., Wu K. Machine learning based feature selection and knowledge reasoning for CBR system under big data. *Pattern Recognition*. 2021. vol. 112(6). no. 107805. DOI: 10.1016/j.patcog.2020.107805.
 20. Smiti A., Elouedi Z. Dynamic maintenance case base using knowledge discovery techniques for case based reasoning systems. *Theoretical Computer Science*. 2020. vol. 817. pp 24–32. DOI: 10.1016/j.tcs.2019.06.026.
 21. Liao T.W., Zhang Z., Mount C.R. Similarity measures for retrieval in case-based reasoning systems. *Applied Artificial Intelligence*. 1998. vol. 12(4). pp. 267–288. DOI: 10.1080/088395198117730.
 22. Fan Z.-P., Li Y.-H., Wang X., Liu Y. Hybrid similarity measure for case retrieval in CBR and its application to emergency response towards gas explosion. *Expert Systems with Applications*. 2014. vol. 41(5). pp. 2526–2534. DOI: 10.1016/j.eswa.2013.09.051.
 23. Oyelade O.N., Ezugwu A.E. A case-based reasoning framework for early detection and diagnosis of novel coronavirus. *Informatics in Medicine Unlocked*. 2020. vol. 20(6). no. 100395. DOI: 10.1016/j.imu.2020.100395.
 24. Gabel T., Godehardt E. Top-down induction of similarity measures using similarity clouds. *International Conference on Case-Based Reasoning*. 2015. pp. 149–16. DOI: 10.1007/978-3-319-24586-7_11.
 25. Mathisen B.M., Aamodt A., Bach K., Langseth H. Learning similarity measures from data. *Progress in Artificial Intelligence*. 2020. vol. 9. pp. 129–143. DOI: 10.1007/s13748-019-00201-2.
 26. Glukhikh I., Glukhikh D. Case-Based Reasoning with an Artificial Neural Network for Decision Support in Situations at Complex Technological Objects of Urban Infrastructure. *Applied System Innovation*. 2021. vol. 4(73). 12 p. DOI: 10.3390/asi4040073.26.
 27. Gluhih I.N., Gluhih D.I. [Algorithms for generating training sets in a system with case-based inference based on example situations]. *Programmnyye produkty i sistemy – Software&Systems*. 2022. vol. 35. no. 4. pp. 660–669. (In Russ.).
 28. Myttenaere A.D., Golden B., Grand B.L., Rossi F. Mean Absolute Percentage Error for regression models. *Neurocomputing*. 2016. vol. 192. pp. 38–48. DOI: 10.1016/j.neucom.2015.12.114.
 29. Wang Y., Wang L., Li Y., He D., Liu T.-Y., Chen W. A Theoretical Analysis of NDCG Type Ranking Measures. *Computer Science*. 2013. 26 p. DOI: 10.48550/arXiv.1304.6480.
 30. Taylor J.R. *An Introduction to Error Analysis: The Study of Uncertainties in Physical Measurements*. Second Edition. Paperback & Clothbound, 1997. 327 p.
 31. Paulson P., Juell P. Using Reinforcement Learning for Similarity Assessment in Case-Based Systems. *IEEE Intelligent Systems*. 2003. vol. 18. no. 4. pp. 60–67. DOI: 10.1109/MIS.2003.1217629.
 32. Glukhikh I., Chernysheva T., Glukhikh D. Neural Network Models for Situation Similarity Assessment in hybrid-CBR. *Journal of Intelligent & Fuzzy Systems*. 2023. vol. 44(15). pp. 1–14. DOI: 10.3233/JIFS-221335.

Glukhikh Igor — Ph.D., Dr.Sci., Professor, Head of department, Department of information systems, Institute of Mathematics and Computer Science; Scientific Director of the Center for System Engineering, Advanced Engineering School, University of Tyumen (UTMN). Research interests: intelligent decision support systems, knowledge bases, precedent-based inference, neural networks in decision making, case-based reasoning. The number of publications — 180. i.n.glukhikh@utmn.ru; 6, Volodarskogo St., 625003, Tyumen, Russia; office phone: +7(932)320-0036.

Prokoshin Alexey — Undergraduate, project leader, Laboratory of agricultural mycology and biological plant protection of the institute of ecological and agricultural biology (x-bio), University of Tyumen (UTMN). Research interests: intelligent systems for phytosanitary monitoring, systems for automated plant growing under controlled conditions in low-volume hydroponics, neural networks for disease recognition and pest identification. The number of publications — 5. a.s.prokoshin@utmn.ru; 6, Volodarskogo St., 625003, Tyumen, Russia; office phone: +7(932)320-0230.

Glukhikh Dmitry — Graduate student, assistant, Department of information systems, University of Tyumen (UTMN). Research interests: intelligent decision support systems, knowledge bases, precedent-based inference, neural networks in decision making, engineering and information automated systems for monitoring technical systems. The number of publications — 25. gluhihdmitry@gmail.com; 6, Volodarskogo St., 625003, Tyumen, Russia; office phone: +7(932)320-0036.