

С. М. Ковалев, М. А. Бутакова, А. Н. Гуда, И. А. Ольгейзер, А. В. Суханов

ОБЗОР ТРУДОВ КОНФЕРЕНЦИИ ПТИ'24

Аннотация. Приводится краткое реферирование наиболее интересных докладов 8-й Международной научной конференции «Интеллектуальные информационные технологии в технике и на производстве» (ПТИ'24), организованной ФГБОУ ВО РГУПС, АО «НИИАС» и Харбинским политехническим университетом (Китай) при поддержке Российской ассоциации искусственного интеллекта, которая проходила в период с 1 по 7 ноября 2024 г. в Китае (гг. Шанхай и Харбин). Открытие конференции ПТИ'24 состоялось в г. Шанхай в рамках Международного форума по обмену опытом CIER 2024 по приглашению Министерства трудовых ресурсов и социального обеспечения Китая, в котором приняли очное участие свыше 2000 ученых из более чем 120 стран.

Целью ПТИ'24 являлся обмен передовым опытом в области фундаментальных и прикладных исследований в сфере искусственного интеллекта, информационных технологий и автоматизации, а также развитие международных контактов. Особое внимание было уделено передовым интеллектуальным технологиям и их применению в различных областях промышленности, в том числе на железнодорожном транспорте.

Ключевые слова: интеллектуальные информационные технологии, искусственный интеллект, интеллектуализация промышленности, Индустрия 4.0.

Для цитирования: Обзор трудов конференции ПТИ'24 / С. М. Ковалев, М. А. Бутакова, А. Н. Гуда [и др.] // Вестник Ростовского государственного университета путей сообщения. – 2024. – № 4. – С. 107–133. – DOI 10.46973/0201-727X_2024_4_107.

Введение

Конференции серии ПТИ проводятся ежегодно с участием ведущих ученых из России и других стран. В разные годы конференции проводились на множестве международных площадок, таких как НТУ «Сириус» (Россия), VSB – Технический университет Остравы (Чехия), Технический университет Варны (Болгария), Стамбульский университет Айдын (Турция). Англоязычные труды конференции публикуются в серии Lecture Notes in Networks and Systems издательства Springer, индексируемой в международных базах данных научного цитирования SCOPUS, INSPEC, WTI Frankfurt eG, zbMATH, SCImago. Среди участников конференции, которая в нынешнем году проходила в Китае, – граждане России, Беларуси, Китая, Индии, Турции, Сирии. Всего на конференцию было подано 126 работ, 78 из которых были приняты для публикации Международным программным комитетом, с докладами выступили 76 специалистов очно и 47 – дистанционно.

ПТИ'2024 была посвящена теоретическим и практическим аспектам применения искусственного интеллекта (ИИ) и интеллектуальных информационных технологий, а также их применению в промышленной сфере. Конференция традиционно рассматривалась как место встречи исследователей и практиков, позволяющее обменяться опытом использования новейших достижений и направлений ИИ и внедрения передовых информационных технологий в различные отрасли производства и социальной сферы.

На конференцию были приглашены ряд ведущих ученых в области ИИ, представивших пленарные доклады:

– член-корреспондент Российской академии наук, заместитель директора Института автоматизации и процессов управления ДВО РАН Валерия Викторовна Грибова выступила с докладом на тему: «Умные стандарты для индустрии 4.0 и 5.0, основанные на графах знаний»;

– главный научный сотрудник, руководитель научно-исследовательской лаборатории проблем компьютерной безопасности СПб ФИЦ РАН, заслуженный деятель науки Российской Федерации Игорь Витальевич Котенко представил участникам конференции доклад «Искусственный интеллект в корреляции событий безопасности в промышленных киберфизических системах: математические модели, реализации и проблемы»;

– ведущий профессор факультета естественных наук Шанхайского университета Цзяо Тонг Ши Джин выступил с докладом о квантовых вычислениях;

– директор Института прикладных математических исследований Карельского научного центра РАН Владимир Викторович Мазалов представил результаты исследований, посвященных динамической устойчивости коалиционных структур;

– академик Китайской академии наук Сюй Зонгбен выступил с докладом на тему: «Как смоделировать методологию обучения? О сути фундаментальных моделей».

Авторы хотели бы выразить личную признательность ректору Харбинского политехнического университета Цзекай Хану и его команде за радушный прием российских участников и всестороннюю поддержку конференции ПТИ.

Доклады конференции были распределены по 11 основным секциям. Ниже приводится краткое реферирование наиболее интересных секционных докладов. Некоторые секции в данной статье объединены в один раздел.

1 Машинное обучение и его приложения, нейронные и байесовские сети

Данная секция была представлена двадцатью докладами.

В работе [1] предложен подход к решению проблемы включения экспертных правил в модели машинного обучения, в частности в нейронные сети, в рамках обучения, основанного на концепции. Первая идея, лежащая в основе этого подхода, состоит в том, чтобы рассматривать экспертные правила как логические функции для понятий, которые ограничивают совместное распределение вероятностей для всех комбинаций значений понятий, т. е. предполагается, что каждая комбинация понятий должна удовлетворять экспертным правилам, в противном случае вероятность комбинации присваивается нулю. Вторая идея состоит в том, чтобы добавить нейронную сеть, генерирующую вероятности комбинаций понятий с помощью слоя, который сопоставляет вероятности понятий с предельными вероятностями понятий и гарантирует, что вероятности будут удовлетворять экспертным правилам для любых входных данных. Предлагаемый подход можно рассматривать как способ сочетания индуктивного и дедуктивного обучения.

Рассмотрено условное совместное распределение вероятностей по концепциям $\Pr(C=c | X=x)$. Все случайные величины концепта являются дискретными с конечными наборами результатов. Следовательно, векторы c могут быть проиндексированы, и общее число различных векторов понятий равно $t = n_0 \cdot n_1 \cdot \dots \cdot n_m$. Предполагается, что функция $M : C^X \mapsto \{1, \dots, t\}$ сопоставляет вектор понятий с его индексом. Обратная функция M^{-1} сопоставляет индекс с соответствующим вектором понятий. Совместное распределение вероятностей $\pi = (\pi_1, \dots, \pi_t)$ определяется следующим образом:

$$\forall c \in C^X, \pi_{M(c)} = \Pr(C = c | X = x).$$

Совместное распределение вероятностей ограничено тем, что оно удовлетворяет экспертным правилам, сформулированным в виде g , поэтому $\Pr(g(C)=1)=1$. Бинарная маска допустимых состояний: $u_k = g(M^{-1}(k))$, $k \in \{1, \dots, t\}$. Ограничения на совместное распределение вероятностей могут быть переформулированы как набор ограничений равенства для компонентов, соответствующих недопустимым состояниям, которые нарушают правила: $\pi_k = 0$, $k \in \{i \in \{1, \dots, t\} | g(M^{-1}(k)) = 0\}$. Общая вероятность при условии, что выполняются экспертные правила $g(C)$:

$$g(C): \Pr(C = c | g(C)=1) = \frac{\Pr(C = c) \cdot \Pr(g(C)=1 | C = c)}{\Pr(g(C))}.$$

В табл. 1 представлен пример комбинаций значений понятия и соответствующих вероятностей.

Таблица 1

**Пример всех комбинаций значений понятия
и соответствующих вероятностей**

$c^{(0)}$	1	1	1	1	1	1	2	2	2	2	2	2
$c^{(1)}$	1	1	1	2	2	2	1	1	1	2	2	2
$c^{(2)}$	1	2	3	1	2	3	1	2	3	1	2	3
π	π_1	π_2	π_3	π_4	π_5	π_6	π_7	π_8	π_9	π_{10}	π_{11}	π_{12}

Далее рассмотрены экспертные правила, представленные в нейросетях, и численные эксперименты.

Фактически авторами предложен способ решения важной проблемы объединения дедуктивной и индуктивной моделей обучения. Предлагаемый подход чрезвычайно прост с точки зрения его реализации. В то же время с вычислительной точки зрения он сложен, так как необходимо анализировать декартово произведение возможных комбинаций понятий и проверять, удовлетворяет ли каждая комбинация экспертному правилу. Авторы применили предложенный подход к графическим данным, так как они могут быть достаточно просто описаны понятиями высокого уровня, и эти понятия связаны с целевыми значениями.

Работа [2] посвящена синтезу и анализу изображений пористых каркасных наноструктур, получаемых в результате химического синтеза, с использованием методов машинного обучения. Авторами предложен современный подход к генерации синтетических изображений исследуемых структур с высокой детализацией с использованием методов компьютерного зрения и машинного обучения. Опираясь передовыми методами анализа изображений, авторы [2] исследуют сложные характеристики и свойства этих структур, чтобы прийти к полному пониманию их поведения и функциональности. Полученные ими результаты не только способствуют развитию дизайна пористых материалов, но и подчеркивают эффективность машинного обучения в создании сложных структурных паттернов, прокладывая путь для нового их приложения в различных областях.

Методы синтеза изображений разработаны с использованием скрипта на языке Python, основанного на математических формулах для генерации эллипсов. Этот подход использует гибкость и эффективность моделей на основе эллипсов для представления сложных и переменных пористых пространств в рамках структур. Для генерации изображений используются формулы:

$$f = \alpha \bigcup_{i=1}^N El_i + \beta I. \quad (1)$$

В уравнении (1) α и β – определяют контрастность изображения, на изображениях $I(k,l)=1$, изображения эллипсов El_i определяются следующим образом:

$$El_i(k,l) = \begin{cases} 1, & \frac{((k-a_i)c_i + (l-b_i)s_i)^2}{A_i^2} + \frac{((k-a_i)c_i - (l-b_i)s_i)^2}{B_i^2} \leq 1; \\ 0, & \frac{((k-a_i)c_i + (l-b_i)s_i)^2}{A_i^2} + \frac{((k-a_i)c_i - (l-b_i)s_i)^2}{B_i^2} > 1, \end{cases} \quad \left(\bigcup_{i=1}^N El_i \right)(k,l) = \max_i El_i(k,l).$$

Уравнение (1), где натуральное число N представляет собой количество пор и контрастов, удовлетворяет ограничениям $\alpha \geq 0$, $\beta \geq 0$, $\alpha + \beta \leq 1$. Контраст $\alpha = \xi\eta$, $\beta = (1-\xi)\eta$ выражается через две независимые случайные величины ξ и η , которые равномерно распределены на интервале $[0,1]$. Центр эллипса (a_i, b_i) равномерно распределен по точкам сетки изображения. Параметры ориентации (c, s)

удовлетворяют следующим ограничениям: $-1 \leq c \leq 1$, $c^2 + s^2 = 1$. Предполагается, что c – однородная случайная величина в интервале $[-1, 1]$, $s = \delta\sqrt{1-c^2}$, $P(\delta=1) = P(\delta=-1) = \frac{1}{2}$.

Генератор использует стандартную метрику: $\rho(M(i, j), R(k, l)) = \sqrt{(k-i)^2 + (l-j)^2}$. Метрика включает параметры и независимые случайные величины A и B . Для их генерации использовались два генератора. Первый генератор использует экспоненциальный закон распределения с параметрами λ_1 и λ_2 . При выборе параметров следует полагаться на средние значения: $EA = \frac{1}{\lambda_1}$, $EB = \frac{1}{\lambda_2}$.

Второй генератор использует β -распределения: $A = \underline{A} + \xi(\bar{A} - \underline{A})$, $B = \underline{B} + \eta(\bar{B} - \underline{B})$, где \underline{A} , \underline{B} – наименьшие и \bar{A} , \bar{B} – наибольшие значения параметров A и B , случайные величины ξ и η не зависят от β -законов распределения:

$$f_{\xi}(x) = \frac{1}{B(\alpha_1, \beta_1)} x^{\alpha_1-1} (1-x)^{\beta_1-1}, \quad x \in [0, 1], \alpha_1 > 0, \beta_1 > 0;$$

$$f_{\eta}(x) = \frac{1}{B(\alpha_2, \beta_2)} x^{\alpha_2-1} (1-x)^{\beta_2-1}, \quad x \in [0, 1], \alpha_2 > 0, \beta_2 > 0,$$

где $B(\alpha, \beta)$ – бета-функция. Параметры α и β требуют дополнительной настройки.

Для анализа пористых материалов основополагающей является сегментация пор, которая позволяет точно определить количество и характеристики пористых каркасных структур, что, в свою очередь, дает возможность получить представление об их структурных и функциональных свойствах. Сегментация пор является нетривиальной задачей из-за сложной и неоднородной природы геометрии пор.

Выделение контуров на изображении относится к операциям типа свертки, и для использования дискретного двумерного преобразования Фурье с применением быстрого алгоритма Кули – Тьюки изображение рассматривается как двумерный тор. Операция свертки изображения f с помощью фильтра g с функцией рассеяния импульсов $g(i, j)$ может быть представлена в виде суммы:

$$(g * f)(i, j) = \sum_{-w}^w \sum_{-w}^w g(k, l) f(i-k, j-l).$$

Ядра фильтров Саппу получены путем дискретного дифференцирования по соответствующим гауссовым переменным ядра. Дифференцирование по гауссовой переменной ядра x приводит к получению ядра:

$$G_x(i, j) = C \left(\exp\left(-\frac{i^2 + j^2}{h}\right) - \exp\left(-\frac{(i-1)^2 + j^2}{h}\right) \right).$$

Другой подход к решению задачи заключается в том, чтобы сформулировать ее как нахождение минимума выпуклого функционала, который нужно вычислить: $(g * f)(0, 0) = (g, f_g)$, где f – изображение без помех, идеальное изображение, а f_g – проекция выпуклого функционала, изображение на фильтре g . В то же время используется шумоизолирующее изображение: $\bar{f} = f + \sigma n$, где n – белый шум. Это применимо к другому алгоритму для вычисления $(\bar{g} * \bar{f})(0, 0) = ((\bar{g}, f_g) + \sigma(\bar{g}, n_g))$, где предполагается, что фильтры g и \bar{g} совпадают. Задача выбора ядра g заключается в следующем:

$$\min_{\bar{g}} \theta, \quad P\left(\max_{f_g \leq \beta} |(\bar{g} - g, f_g) + \sigma(\bar{g}, n_g)| \leq \theta\right) \geq \alpha, \quad (2)$$

где θ – погрешность вычисления производной.

Задача, описанная в (2), преобразуется в предположении, что случайная величина и шум распределены в соответствии с нормальным законом распределения. Из нормальности следует, что

$$\theta = \beta \bar{g} - g + \sigma \Phi^{-1} \left(\frac{1 + \alpha}{2} \right) \bar{g}, \text{ где } \Phi^{-1}(x) \text{ – обратная функция Лапласа.}$$

В работе [3] рассматривался подход к исследованию плохой повторяемости в данных, основанный на анализе сезонной динамики годового цикла для точной идентификации различных видов древесных растений, в частности кленов. Были использованы алгоритмы машинного обучения (МО) Random Forest (RF) и Gradient Boosting (GB), в том числе метод слияния спектральных данных с гиперспектральной камеры с погодными данными, такими как температура, осадки и длина светового дня, влияющими на развитие древесных растений в годовом цикле. Объединение данных позволило учесть взаимосвязь между спектральными характеристиками и климатическими условиями, что привело к повышению качества идентификации видов алгоритмами машинного обучения на 13,21 %. Использование слияния спектральных и климатических данных позволило создать комплексную модель, учитывающую спектральные характеристики и их связь с погодными условиями, что повышает точность классификации видов, а также позволяет оценить точность алгоритмов машинного обучения в сезонной динамике годового цикла для всех изученных видов.

Исследование проводилось в Южном федеральном университете в период с 2021 по 2023 г. Объектами исследования послужили пять видов кленов – *Acer campestre* L., *A. negundo* L., *A. saccharinum* L., *A. platanoides* L. и *A. ibericum* Bieb. Чтобы оценить различие спектральных данных для каждого вида, был проведен разведочный анализ данных Exploratory Data Analysis (EDA), результаты которого приведены на рис. 1.




Рис. 1. Среднее значение спектров по дням за 2022 год

Первым этапом проведение анализа данных и идентификации видов, стал эксперимент с использованием спектральных данных, без учета погодных условий. На втором этапе проведения анализа данных и идентификации видов было выполнено объединение спектральных данных с метеорологическими данными, что позволило повысить точность модели машинного обучения.

Все результаты оценки точности моделей сведены в табл. 3, где можно увидеть прирост точности моделей при объединении спектральных и метеорологических данных. Точность алгоритма RF выросла на 12,83 %, алгоритма GB – на 13,21 %. Алгоритм GB показал себя лучше по сравнению с RF на 7,51 %.

Таблица 2

Результаты оценки точности модели при анализе данных и идентификации видов

Метод	Использованный набор данных	Точность
Random Forest	Спектральные данные	49,51 %
Gradient Boosting	Спектральные данные	51,87 %
Random Forest	Спектральные и метеорологические данные	55,86 %
Gradient Boosting	Спектральные и метеорологические данные	58,72 %

Авторы работы [4] представили подход к построению моделей условных вариационных автоэнкодеров (C-VAE) с нечеткими выводами при классификации. Этот подход сохраняет возможности вариационного автоэнкодера (VAE) по распутыванию, одновременно выполняя кластеризацию латентного пространства. Нечеткая модель C-VAE предоставляет полезные возможности для обнаружения аномалий, используя частично помеченные наборы данных и контролируемую генерацию новых образцов. В данной работе рассмотрен один из аспектов инструментария нечеткой логики, а именно нечеткие термины, реализованные в нечетком слое для ML-фреймворка PyTorch. Следует отметить, что представленный нечеткий слой уже может быть использован для построения нечетких или нейро-нечетких систем. В частности, можно строить мамдани-подобные системы вывода, сочетая нечеткий слой с линейными и softmax слоями. Исходный код доступен на репозитории GitHub <https://github.com/kenoma/pytorch-fuzzy>.

В своем исследовании авторы использовали следующие методы: вариационные автоэнкодеры (VAE), условные автоэнкодеры (C-VAE), нечеткие C-VAE. Предложена архитектура нечеткого C-VAE, в которой применяются дополнительные условия для реорганизации структуры латентного пространства. Реорганизация достигается за счет использования нечетких функций термов, где каждый терм связан с одним условием, т. е. меткой. Для представления нечеткой функции терма используется многомерная функция Гаусса:

$$v(z, A_i) = e^{-\left\| \begin{bmatrix} A_i \cdot \tilde{z} \\ 1 \dots m \end{bmatrix} \right\|^2},$$

где m – размер латентного пространства, I – номер терма (т. е. номер класса), $\tilde{z} = [z_1, z_2, \dots, z_m, 1]$ и A_i – матрица преобразования в виде:

$$A_{(m+1) \times (m+1)} = \begin{bmatrix} a_{1,1} & \dots & a_{1,m} & c_1 \\ \vdots & \dots & \vdots & \vdots \\ a_{m,1} & \dots & a_{m,m} & c_m \\ 0 & \dots & 0 & 1 \end{bmatrix},$$

с положением центра $c_1 \dots c_m$, и $a_{k,l}$ – матричный элемент, отвечающий за масштабирование и выравнивание гауссианы в m -мерном пространстве. Такое представление многомерной гауссовой терм-функции легко использовать в любом современном фреймворке машинного обучения. Набор $\{v(z, A_i)\}$ назван нечетким слоем. Идея нечеткого слоя заключается в том, что в процессе обучения каждый входной вектор z принудительно группируется ближе к центру соответствующей терм-функции. Функции распутывания VAE в сочетании с возможностями кластеризации нечеткого слоя обеспечивают контролируемую процедуру обучения латентного пространства, которая может быть полезна для обнаружения аномалий и других задач.

Для обучения нечеткого C-VAE авторы использовали ту же функцию потерь, что и в стандартном VAE, с добавлением потерь нечеткого слоя $FZ\left(\tilde{y}, y\right)$:

$$\text{Loss} = \text{MSE}\left(\tilde{x}, x\right) + \text{KL}\left(\mu, \log \sigma^2\right) + \text{FZ}\left(\tilde{y}, y\right),$$

где $\text{MSE}\left(\tilde{x}, x\right)$ – потери при реконструкции, $\text{KL}\left(\mu, \log \sigma^2\right)$ – KL -расхождение, а $\text{FZ}\left(\tilde{y}, y\right)$ – средняя квадратичная ошибка между выходным и целевым условным вектором.

В этой статье авторы использовали набор данных MNIST 1 в качестве игровой площадки для демонстрации ключевых концепций нечеткого C-VAE. Сравнивается сеть FuzzyC-VAE, ванильная сеть VAE и сеть, которая является топологическим эквивалентом сети нечеткого C-VAE с нечеткой частью, замененной двухслойным перцептроном csoftmax (MLPC-VAE).

С помощью представленного нейросетевого компонента авторы модернизировали фреймворк C-VAE и продемонстрировали его потенциальное применение в обнаружении аномалий, генерации синтетических данных и обучении на частично разделенных наборах данных. Нечеткая модель C-VAE по своей сути предназначена для реорганизации латентных многообразий в соответствии с экспертными знаниями в процессе обучения. В этой модели нечеткие термины служат в качестве контролируемого кластера. Многомерная гауссова функция была продемонстрирована как эффективное средство кондиционирования при использовании в качестве характеристической функции. На наборе данных MNIST было продемонстрировано, что система, основанная на классическом многослойном перцептоне, менее эффективна, чем нечеткий C-VAE.

В статье [5] описывается эффективная методика решения проблемы, достаточно часто возникающей в задачах видеонаблюдения и технического зрения, когда угол обзора камер достаточно широк, а обнаруженные объекты заслоняются перспективой. В основе предложенной авторами методики лежит обнаружение объектов на перспективных трансформированных (деформированных) изображениях. Такое преобразование позволяет упростить пространственную структуру изображения и, следовательно, его анализ. В некоторых случаях после предложенного преобразования задача обнаружения может быть переформулирована как одномерная. В работе предложен ряд специализированных метрик для измерения качества задачи одномерного обнаружения, а также несколько способов использования упрощенной структуры изображения при обучении модели обнаружения. Предложенные методы проиллюстрированы практическим применением позиционирования вагонов на классификационной чаше сортировочной грузовой железнодорожной станции.

Когда выходные данные модели являются двоичными, они просты, однако в рассматриваемом в [5] случае псевдоодномерного обнаружения выходные данные модели, а также наземные данные представляются в виде сегментов. В этом случае положительные моменты могут быть формализованы по аналогии с широко используемыми метриками в детектировании, на основе пересечения сегментов. Если предсказанный участок значительно пересекает один из сегментов наземных истин, то он считается истинно положительным, если нет – считается ложноположительным, все сегменты наземных истин, не пересекающиеся ни с одним из прогнозируемых сегментов, считаются ложноотрицательными. Для количественной оценки значимости пересечения авторы адаптировали известную метрику IoU к одномерному случаю:

$$\begin{aligned} \cap_{1D}(x, y) &= (\max(l(x), l(y)), \min(r(x), r(y))), \\ \cup_{1D}(x, y) &= (\min(l(x), l(y)), \max(r(x), r(y))), \\ \text{IoU}_{1D}(x, y) &= \frac{\cap_{1D}(x, y)}{\cup_{1D}(x, y)}, \end{aligned}$$

где x, y – два сегмента, а $l(\cdot)$ и $r(\cdot)$ – левая и правая границы этих сегментов (начало и конец сегмента соответственно).

Метрики обнаружения модели определяются следующим образом:

$$\text{Recall}_{1D}@ \theta = \frac{\sum_i |TP@ \theta(Y_i, \hat{Y}_i)|}{\sum_i |Y_i|},$$

¹ Deng L. The MNIST database of handwritten digit images for machine learning research [best of the web] // IEEE Signal Processing Magazine. – 2012. – Vol. 29(6). – P. 141–142. – URL: <https://doi.org/10.1109/MSP.2012.2211477>.

$$\text{Precision}_{1D}@\theta = \frac{\sum_i |TP@ \theta(Y_i, \hat{Y}_i)|}{\sum_i |\hat{Y}_i|},$$

где Y – набор истинных сегментов для области интереса; \hat{Y} – набор прогнозируемых сегментов для области интереса; θ – пороговое значение для IoU_{1D}.

Качество позиционирования измеряется только для истинно положительных результатов и определяется на основе граничной ошибки для каждого правильно распознанного сегмента:

$$PE@ \theta = \sum_i \sum_{y, \hat{y} \in TP@ \theta(Y_i, \hat{Y}_i)} |l(y) - l(\hat{y})| + |r(y) - r(\hat{y})|.$$

Функция потерь исходной модели YOLO [5] включает в себя следующие компоненты:

$$\mathcal{L}_{MSE} = \lambda_{coord} \sum_i \sum_j \mathbb{I}_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \lambda_{coord} \sum_i \sum_j \mathbb{I}_{ij}^{obj} \left[(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2 \right].$$

Здесь i перебирает ячейки изображения и j – по потенциальным ограничивающим прямоугольникам в каждой ячейке, умножение на индикатор \mathbb{I}_{ij}^{obj} означает, что потеря наказывает ошибку координат ограничивающего прямоугольника, если этот предиктор «ответственен» за основной блок истины (т. е. имеет наибольшее значение IoU среди всех предикторов в этой ячейке сетки).

Для того чтобы учесть разную значимость измерений в такой функции потерь, добавляется весовой коэффициент $\lambda \in (0; 1)$ для одного из измерений:

$$\begin{aligned} \mathcal{L}_{MSE}^* = \lambda_{coord} \sum_i \sum_j \mathbb{I}_{ij}^{obj} [(1 - \lambda)(x_i - \hat{x}_i)^2 + \lambda(y_i - \hat{y}_i)^2] + \\ + \lambda_{coord} \sum_i \sum_j \mathbb{I}_{ij}^{obj} \left[(1 - \lambda)(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + \lambda(\sqrt{h_i} - \sqrt{\hat{h}_i})^2 \right]. \end{aligned}$$

Статья [6] посвящена использованию алгоритмов однозадачного и многозадачного обучения с подкреплением для автономного мобильного робота. Авторы демонстрируют универсальность моделей обучения с подкреплением через эксперименты на роботе Mobile Aloha, который обладает возможностями как манипуляции, так и навигации. Основная идея работы заключается в демонстрации использования различных типов RL-алгоритмов (одно- и многозадачных, RL – Reinforcement Learning, обучение с подкреплением) для мультиконтрольных роботов, что ранее не было достаточно исследовано. Авторами приведены сравнительные результаты экспериментов с современными алгоритмами обучения с подкреплением для различных типов задач, включая навигацию, манипуляцию и их комбинацию.

В рамках единой структуры марковского процесса принятия решений (MDP) формулируются задачи навигации, манипуляции и мобильной манипуляции. Каждая задача моделируется из следующих составляющих:

- *пространство состояний* (S): представляет все возможные конфигурации робота и его окружения. Оно включает пространственные координаты робота, ориентацию, скорость, состояние манипулятивных приводов (например, открыт или закрыт захват) и положение соответствующих объектов (например, препятствий, кубиков);
- *пространство действий* (A): представляет все действия, которые робот может выполнять. Стоит из вектора управления навигацией, который включает линейную и угловую скорости, и вектора, включающего управление каждым сочленением манипулятора;
- *динамика переходов* (P): определяет вероятности $P(s'|s, a)$ того, что выполнение действия a в состоянии s приведет к состоянию s' ;
- *функция вознаграждения* (R): функция $R(s, a, s')$, предоставляющая скалярный сигнал обратной связи после перехода из состояния s в состояние s' в результате действия a .
- *терминальные условия*: каждая задача имеет условие, при котором она считается завершённой. Оно включает достижение целевого местоположения (робота и/или объекта манипуляции) в отведенное для этого время.

MDP представлен кортежем (S, A, P, R, γ) , где γ коэффициент дисконтирования. Цель в каждой задаче – найти политику $\pi: S \rightarrow A$, которая максимизирует ожидаемое накопленное вознаграждение:

$$\max_{\pi} \mathbb{E}[\sum_{t=0}^{\infty} \gamma^t R(s_t, a_t, s_{t+1})],$$

где s_t – состояние в момент времени t , $a_t = \pi(s_t)$ – действие, выполненное в соответствии со стратегией π , s_{t+1} – состояние, полученное в результате действия a_t .

Для управления базой использовалась модель робота с дифференциальным приводом на колеса. Контроллер принимает на вход желаемые линейную и угловую скорости $[u, \omega]$ и выдает желаемую угловую скорость для каждого колеса $[\dot{\theta}_L, \dot{\theta}_R]$. Чтобы продемонстрировать управление колесами робота, авторами был разработан соответствующий алгоритм.

Для оценки производительности алгоритмов RL авторы [6] провели эксперименты в симуляционной среде с использованием Mujoco и OpenAI Gym.

Хотя TDMP2 продемонстрировал многообещающие результаты при выполнении нескольких задач без необходимости настройки под конкретные задачи, другие алгоритмы также показали свои сильные и слабые стороны. PPO и SAC, несмотря на то что требовали более специфической настройки гиперпараметров с помощью таких инструментов, как RayTune и RLlib, все же смогли хорошо работать в задачах с меньшими размерностями действий. DreamerV3, используя свою модель размера S , показал среднюю производительность, особенно в сложных сценариях. С другой стороны, как FQL, так и DFQL продемонстрировали низкую производительность, что может быть связано с тем, что задачи навигации, манипуляции и мобильной манипуляции включают сложные пространства состояний и действий. Поэтому FQL и DFQL, будучи более простыми по своей природе, часто не обладают достаточной сложностью для эффективной работы с высокоразмерными непрерывными пространствами состояний и действий.

Следует также отметить еще работу [7] представленную в данной секции, в которой рассмотрено уточнение ранее предложенного алгоритма поиска приближенного канонического представителя фрагментов знаний (ФЗ), использующего метод Монте-Карло и ищущего среднее между большим числом ФЗ со скалярными оценками. ФЗ хранят тесно связанную информацию о предметной области, которая формализуется, в частности, в виде набора квантов со скалярными или интервальными оценками вероятности истинности. В случае дефицита вычислительных и временных ресурсов может быть полезен поиск канонического представителя ФЗ – перехода от объектов с интервальными оценками к наиболее репрезентативным объектам со скалярными оценками. Уточнение алгоритма заключается в замене гамма-распределения, с помощью которого генерировались скалярные оценки, на экспоненциальное распределение. В результате было экспериментально показано, что получаемые в таком случае канонические представители ФЗ формируются в 8 раз точнее.

2 Промышленная интеллектуализация

Традиционно на конференции большая часть работ посвящается прикладным технологиям искусственного интеллекта. В нынешнем году в данную секцию было подано четырнадцать докладов о применении ИИ в железнодорожной [8–12], авиастроительной [13], автотранспортной [14] областях, а также принципах внедрения искусственного интеллекта в индустрию [15, 16]. Подробная аннотация этих работ приведена ниже в настоящем разделе.

В работе [8] исследуются логические спецификации для быстрого прототипирования сложных структур и процессов, в том числе транспортных. Используется язык в классической логике предикатов с равенством и отрицаниями, обладающий вычислимой семантикой. Исполнение таких описаний может иметь экспоненциальные оценки сложности. Выделены достаточные условия и соответственно подклассы таких спецификаций, сложность построения прототипов и анализаторов по которым может быть понижена до полиномов низких степеней. Выделены системы, разрешимые за время с линейной памятью, где n – мощность задаваемых отношений, m – мощность определенности функций и отношений. Выразительность полученных классов спецификаций, как показало практическое использование, достаточна для прототипирования в различных предметных областях.

В другой работе, посвященной железнодорожной автоматизации [9], авторы представляют интеллектуализацию планирования работы грузовой сортировочной станции на основе «данных от колеса». Под «данными от колеса» авторы имеют в виду собственную концепцию данных, которые представляют собой информацию со всевозможных датчиков – рельсовых цепей, индуктивных датчиков

счета осей, радиочастотных меток, а также камер видеонаблюдения. Получение таких данных осуществимо благодаря разработанной авторским коллективом системе контроля и подготовки информации о перемещениях вагонов и локомотивов на станции в реальном времени (СКПИ ПВЛ РВ). СКПИ ПВЛ РВ осуществляет слияние информации от различных источников данных низовой автоматики и систем автоматизации технологических процессов для получения фактических данных о перемещениях подвижных единиц на станции в реальном времени.

Увеличение пропускной способности, уменьшение реального простоя вагонов на грузовых станциях является в настоящий момент одной из важнейших задач, поскольку большую часть своего жизненного цикла грузовой вагон проводит на станциях. Нелинейность процессов на станциях обусловлена наличием множества неопределенных факторов, влияющих на процессы диспетчеризации. Для решения задачи оптимизации управления маневровой работой в реальных условиях нелинейности процессов на грузовых станциях видится необходимой разработка цифрового двойника станции, основанного на реальных данных вагонной модели станции, полученных от низовых устройств. Такой цифровой двойник, что особенно важно, должен обладать возможностью прогнозирования критических параметров на основании накопленной статистики по работе конкретного объекта.

На основании вагонной модели СКПИ ПВЛ РВ позволяет автоматически беспристрастно фиксировать и протоколировать объективные показатели сортировочной станции, такие как начало и конец технологической операции, время переработки вагона на станции и пр. В настоящее время СКПИ ПВЛ РВ используется только как средство фиксации первичных данных, получаемых от напольного оборудования. При этом показатели станции рассчитываются, как правило, на основе грубой обобщенной (часто необъективной) информации, внесенной вручную дежурным персоналом или на основе плановых значений. Эта информация часто не соответствует реальным оперативным данным, так как она сформирована человеком. Поэтому показатели, рассчитываемые на основании этих данных, зачастую не соответствуют действительности. В связи с чем реальную длительность конкретных операций невозможно проанализировать, что не позволяет максимально эффективно использовать перерабатывающую способность больших станций, таких, например, как ст. Челябинск-Главный.

В 2023 г. авторским коллективом в инициативном порядке разработан дополнительный функционал СКПИ ПВЛ РВ, описанный в статье [9], который позволяет автоматизировать расчет и планирование станционной работы. На основании реальной информации авторы рассчитали относительную загрузку парков станции в течение недели по двум системам – четной и нечетной. На рис. 2 отображено количество вагонов в процентном соотношении к общей вместимости парка, где парк Г – парк приема, парк Д – сортировочный парк, и парк В – парк отправления.




Рис. 2. Загруженность парков в период 4–13 ноября 2023 г.

На основании полученных данных авторы также представляют моделирование работы станции для планирования работы с учетом появления нештатных ситуаций. На рис. 3 показан период остановки работы станции на основе имитационного моделирования при использовании реальных данных.

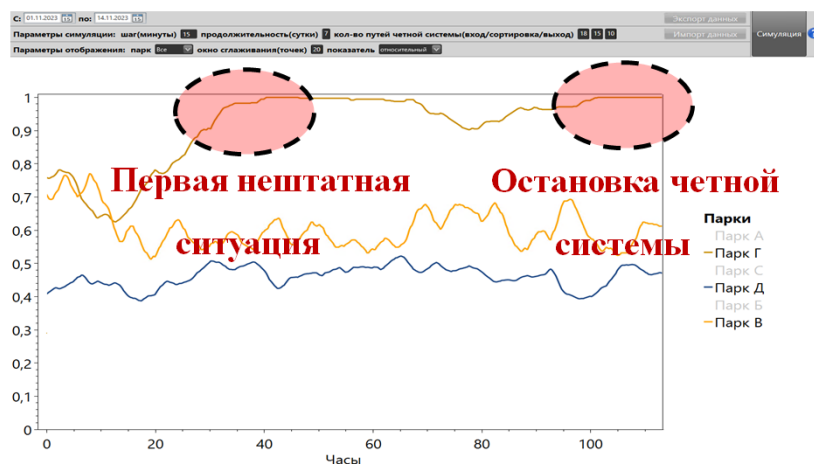


Рис. 3. Имитация ремонта путей с остановкой части станции в течение суток

В другой работе, посвященной интеллектуализации сортировочных станций, представлено описание функциональной безопасности систем технического зрения при их внедрении в железнодорожную инфраструктуру [10]. Авторы предлагают способ реализации доказательства функциональной безопасности сложных технических систем, которые основаны на машинном обучении и, соответственно, имеют неопределенное поведение при их промышленной реализации. Способ заключается в использовании датчиков «низовой автоматики» для исключения случаев опасных отказов систем искусственного интеллекта. В работе также показана реализация предложенного способа на реальных объектах сети ОАО «РЖД» (рис. 4).




Рис. 4. Использование датчиков «низовой автоматики» в комплексе с системой компьютерного зрения

Темой другого доклада конференции стали результаты еще одной работы, посвященной компьютерному зрению на сортировочной станции [11]. В статье авторы предлагают объединить методы, основанные на работе с данными (data-driven), с методами, основанными на работе со знаниями (knowledge-driven). В данной работе изложен новый гибридный подход к решению задачи контроля подвижных единиц в сортировочном парке грузовой станции, сочетающий алгоритм компьютерного

зрения (data-driven) для выявления ключевых объектов на снимках видеокамер и алгоритм анализа данных (knowledge-driven), полученных от дискретных устройств сортировочного парка и сортировочной горки. Исследование рассматриваемой проблемы является актуальным, так как существующие на рынке решения не обеспечивают точного и исчерпывающего информирования о движении вагонов и локомотивов в сортировочном парке. Авторами предлагается объединение искусственной нейронной сети глубокого обучения для распознавания подвижных единиц при построении data-driven алгоритма и виртуальной модели сортировочного парка, основанной на мультисенсорных данных, при построении knowledge-driven алгоритма. Такое сочетание позволяет как сгладить ошибки первого и второго рода data-driven, обусловленные невозможностью получения всевозможных вариаций подвижных единиц в кадрах видеокамер, так и составить наиболее полную статическую и динамическую картину сортировочного парка, которую невозможно получить на основе дискретных сенсоров в сортировочном парке. В работе приводятся результаты работы алгоритма и его преимущества перед существующими решениями для контроля подвижных единиц в сортировочном парке. Предлагаемый подход является актуальным при решении задач компьютерного зрения при неполноте и зашумленности входных данных – изображений. В заключение авторами представлена реализация проведенного исследования на реальном объекте внедрения в области железнодорожного транспорта. Показано, как с использованием knowledge-driven составляющей реализовано распознавание зашумленных объектов (рис. 5).



Рис. 5. Распознавание зашумленных объектов:
а – зашумленное изображение; *б* – отображение вагонов на интерфейсе системы внедрения предлагаемого в [11] алгоритма

Еще одно исследование, представленное на ПТГ'24 и относящееся к интеллектуализации железнодорожного транспорта, посвящено применению метода глубокого обучения с подкреплением для минимизации нагрузок в поезде [12]. Разработана модель продольной динамики поезда, включающая дифференциальные уравнения. Определение профиля пути позволяет проводить реалистичные вычислительные эксперименты. Углубленное обучение с подкреплением используется для изучения стратегий управления тормозными и тяговыми усилиями, направленных на минимизацию нагрузок в поезде и повышение безопасности и эффективности движения на железнодорожном транспорте. Авторами построены модели неровностей пути на плане и определены параметры нормального распределения, что позволяет при необходимости генерировать их. Получены дифференциальные уравнения движения поездов для произвольного количества единиц подвижного состава и вариантов состава поезда.

На ПТГ'24 было также доложено о результатах полезного для авиастроительной области исследования [13]. В данной статье предложен подход и программное средство для автоматизации создания баз знаний на основе анализа и преобразования концептуальных моделей в виде диаграмм переходов состояний (рис. 6). Авторы представили программное средство, реализующее предлагаемый подход – KMS (Knowledge Modeling System), которое поддерживает моделирование знаний в виде диаграмм переходов состояний. Основной особенностью предлагаемого подхода и средства является поддержка генерации кодов баз знаний на основе построенных диаграмм. В качестве целевых формализмов представления знаний выбраны продукция, таблицы решений и онтологии. В частности, в качестве основных языков представления знаний используются CLIPS (Integrated Production System) и OWL (Web On-

tology Language). Разработанный подход и программное средство были применены для прототипирования базы знаний при решении задач в области обеспечения техногенной безопасности авиационного оборудования.




Рис. 6. Основные этапы подхода из исследования [13]

В работе [14] предложено решение для интеллектуализации автотранспортной сферы. Авторы демонстрируют разработанный многоагентный подход при реализации проектирования перекрестков (рис. 7), а также варианты реализации предлагаемых решений в соответствии с МЭК 61499 «Функциональные блоки для промышленных систем управления».




Рис. 7. Структура многоагентного подхода из [14]

В [15] рассматривается метод обеспечения интеллектуализации взаимодействия технической системы с пользователем, позволяющий отражать контекст и оценки состояния системы в терминологии конкретного пользователя. Метод дает пользователю возможность определять на естественном языке логику формирования осмысленных оценок состояния системы на основе наблюдаемых параметров и выделять для каждой оценки необходимые модальности, используемые для оповещения. Суть метода интеллектуализации заключается в том, что общий канал взаимодействия между пользователем и технической системой не заменяется, как это предлагается в рассмотренных во втором разделе статьи

методах, а дополняется интеллектуальным компонентом. Такой интеллектуальный компонент работает в одностороннем режиме и выполняет функции интерпретации формируемых базовым интерфейсом технической системы сигналов и информации. Интерпретация подразумевает формирование оценки состояния системы в определенном конечном пользователем виде. Интеллектуальная часть такого интерфейса, в отличие от известных подходов, использует принципы не искусственного, а естественного интеллекта. Таким образом, интеллектуализация обеспечивается на уровне учета индивидуальных особенностей пользователя, которые позволяют синтезировать частные механизмы взаимодействия, учитывающие особенности его естественного интеллекта.

В другой работе, посвященной формализации требований к прикладному искусственному интеллекту [16], обсуждается вопрос создания машиночитаемого контента (SMART, Standards Machine Applicable, Readable and Transferable), который может быть воспринят как естественным, так и искусственным интеллектом. Авторы предлагают двухуровневую онтологию представления документов, которые могут быть восприняты и человеком, и машиной, а также представляют прикладное использование разработанных принципов для подготовки медицинских рекомендаций (рис. 8).

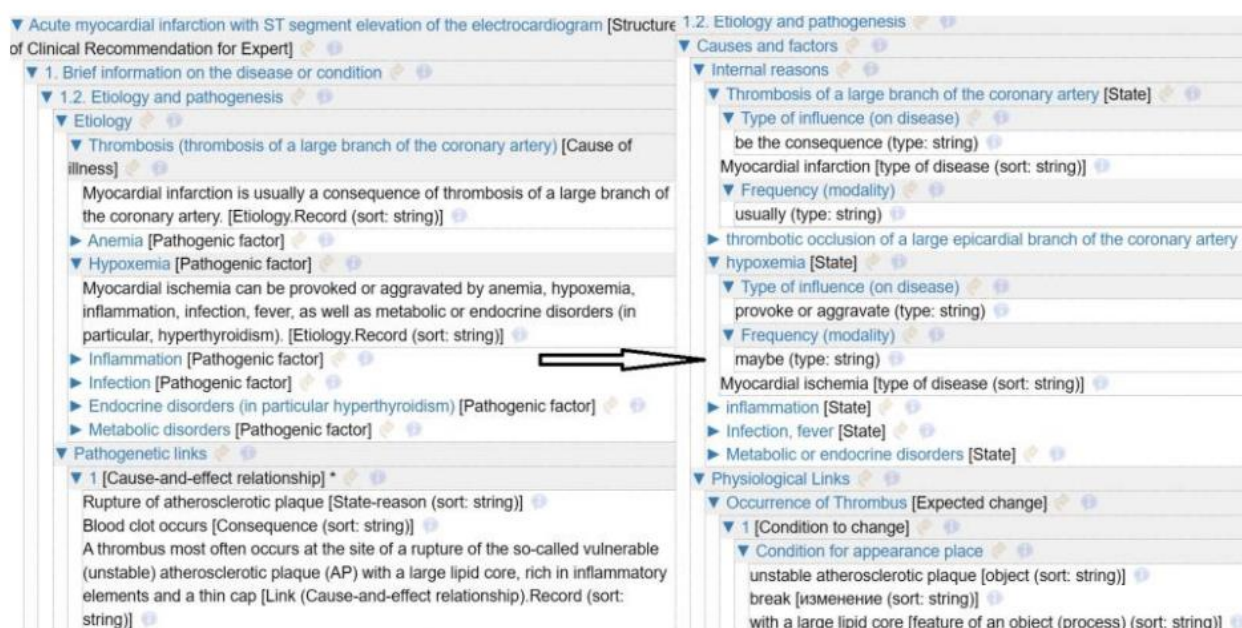


Рис. 8. Прикладное использование онтологий, предлагаемых в работе [16]

3 Кибербезопасность в Индустрии 4.0

Начиная с 2022 г. в ПТИ традиционно выделяется секция, посвященная передовым решениям в области кибербезопасности. В 2024 г. данная секция представлена исследованиями по обнаружению ботнетов [17], аномалий [18–20] и информационных атак [21]. В качестве инструментария авторы предлагают большое разнообразие методов: от федеративного обучения [22] до использования цифровых двойников [23].

Так, в [17] авторы предлагают подход к обнаружению активности ботнета, базирующийся на выявлении аномалий сетевого трафика с помощью машинного обучения. Также в статье рассмотрены основные существующие типы ботнетов на основе классификации по цели атаки и типу контроля. Кроме того, обозначены ключевые современные методы обнаружения их активности. На основании проведенного исследования, сделан вывод о том, что существующие методы обнаружения могут стать недостаточно эффективными по мере усложнения ботнетов с течением времени. Были проведены эксперименты по обнаружению ботнетов с помощью различных алгоритмов машинного обучения при использовании современных наборов данных и сделан вывод о том, какие алгоритмы наиболее эффективны для выполнения этой задачи. Статья будет полезна для разработчиков систем обнаружения вторжений, а также для исследователей в области компьютерной безопасности.

В [18] авторы предложили способ проектирования моделей для детектирования аномального поведения киберфизических систем (КФС). Система показывает высокую точность классификации на

данных, полученных при оказании различных типов деструктивного воздействия. Перспективным направлением дальнейших исследований является реализация метода многоклассовой классификации по определенному типу оказываемого воздействия, что повысит эффективность принятия контрмер по сокращению пагубного влияния на защищаемую систему.

О поиске аномалий в киберфизических системах поднят вопрос и в [19]. В этом исследовании предлагается основанная на совместной информации комплексная стратегия обнаружения аномалий, использующая Gradient Boosting Machine (GBM) и Light GBM для обнаружения киберфизических аномалий и обеспечения безопасности КФС (рис. 9). Предлагаемая методология базируется на основе набора данных о физическом и сетевом оборудовании в режиме реального времени, полученных на испытательном стенде по распределению воды. Предложенное решение позволило повысить точность на 4,6–6,0 % и 0,7–1,8 %, а также снизить частоту ложных срабатываний в сети и физических наборах данных на 4,7–6,3 % и 0,7–1,4 % соответственно.

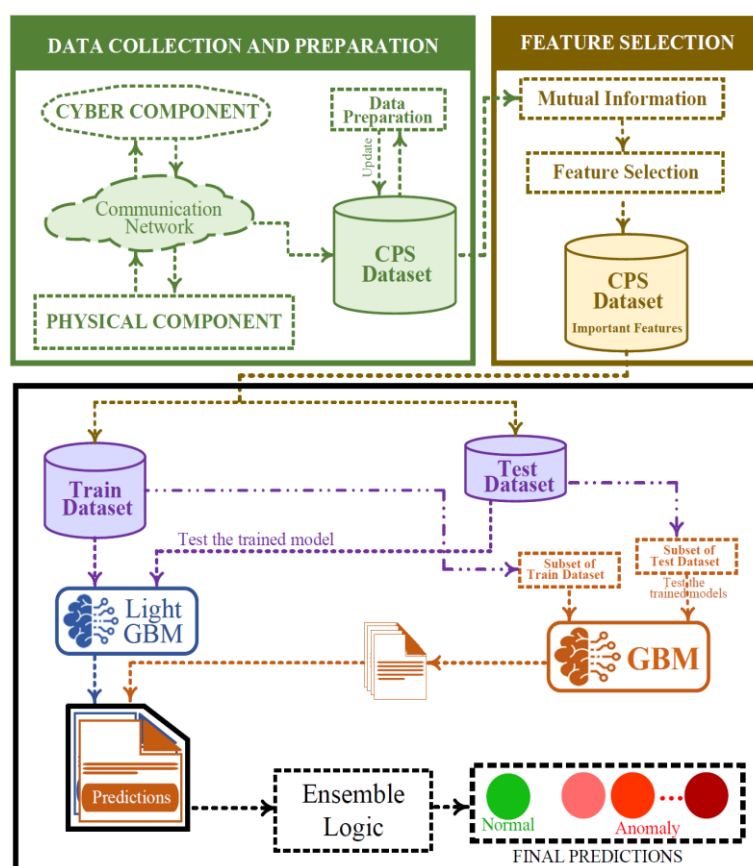


Рис. 9. Предложенный в [19] алгоритм

В [20] для решения поиска аномалий авторами предложено использование распределенных вычислений. Федеративное обучение (FL) – это парадигма распределенного машинного обучения, при которой несколько сторон совместно обучают общую модель, сохраняя конфиденциальность своих данных. Однако этот совместный процесс предоставляет клиенту полный доступ к глобальной модели, тем самым повышая риск утечки модели. Чтобы снизить этот риск, крайне важно разработать методы проверки владения моделью и отслеживания вредоносных клиентов, ответственных за утечку модели. В существующих методиках часто используются методы создания водяных знаков в формате «белого ящика», при этом процесс проверки водяных знаков требует прямого доступа к внутренним параметрам и структуре модели. Этот подход неосуществим во многих реальных сценариях, т. к. многие потенциально подозрительные модели неохотно раскрывают свои внутренние параметры. В работе [20] предложен полностью «черный ящик», который решает эти проблемы. Метод заключается в обработке исходных данных для создания основы авторского набора триггеров водяных знаков. Результаты экспериментов показывают, что данный подход сохраняет точность исходной задачи, обеспечивая при этом проверку правообладателя и отслеживание источников утечки. Кроме того, такой метод демонстрирует высокую устойчивость к различным атакам по удалению водяных знаков и их обнаружению.




Рис. 10. Метод, предложенный в [20]

Основой такого метода является очистка (дистилляция) данных путем получения оптимизированного набора параметров θ^* из начального набора параметров θ_0 :

$$\min J(\Phi) = \frac{1}{|B|} \sum_{i=1}^{|B|} \ell(f(x_i; \theta^*), y_i),$$

$$\text{subject to } \theta^* = \text{OPT}(\theta_0, D_t; \alpha_0, \beta_0, \ell, T),$$

где α_0, β_0 – скорость и момент обучения для $\text{OPT}(\cdot, \cdot)$; $J(\Phi)$ – потери обобщения на B (minibatch); D_t – тестовый набор данных; $\ell(f(x; \theta^*), y)$ – функция потерь.

В таком виде очищенный набор данных будет поддерживать сильную корреляцию с оригинальным набором:

$$E_{(x,y)} \sim D_{Te} [m(f(x; \theta^*), y)] \cong E_{(x,y)} \sim D_{Te} [m(f(x; \theta'^*), y)],$$

где m – метрика (например, точность).

Моделью всегда является нейроклассификатор $f(x; \theta^*)$, параметризованный на θ и обученный на функции потерь $\ell(f(x; \theta^*), y)$.

После очистки набора данных предлагается «склейка» (\oplus) данных с одинаковыми признаками:

$$D_T \{x_i, y_i\} \oplus D_T \{x_j, y_j\} = D_T \{x_{ij}, y_j\}.$$

На полученный набор данных накладываются водяные знаки для последующей защиты от их потери. При этом используется критерий минимального влияния водяного знака на исходное изображение:

$$\min_{\theta_k} H'(\theta_k^f) = H(\theta_k^f) + \frac{\beta}{2} \|\theta_k^f - \theta_g^f\|^2,$$

где θ_k^f – исходный параметр глобальной модели.

На выходе происходит тестирование «подозрительных» моделей. Та модель, которая дает результат выше заданного порога, признается вредоносной.

И, наконец, в [23] предложен метод цифровых двойников. Авторами обоснована необходимость внедрения более активного подхода с точки зрения понимания, повышения осведомленности и борьбы с непреднамеренными инсайдерскими угрозами. Был предложен и апробирован новый эффективный метод защиты информационных систем от инсайдерских угроз, основанный на моделировании на основе данных и машинном обучении, с использованием цифрового двойника, который обеспечивает безопасную и благоприятную среду для решения операционных задач в эпоху индустрии 4.0/5.0.

4 Интеллектуальные технологии в социальных и медицинских науках

Всего в рамках указанной секции было зачитано 10 докладов.

В работе [24] рассмотрен метод нечеткого ситуативного управления, предназначенный для идентификации состояний пациента в условиях неполноты информации. Управление медико-технологическим процессом, включающим обследование, диагностику и лечение, осуществляется с использованием интеллектуальной системы медико-технологического процесса (СМТП). Она представляет собой набор компонентных моделей, типы и разновидности которых перечислены в табл. 3.

Таблица 3

Компонентные модели для построения композиционной гибридной модели «Поступление в стационар»

Компоненты ССМТП	Тип компонентной модели
Осмотр больного в приемном отделении	Нечетко-логическая модель
ЭКГ-исследование	Нейросетевая модель
Лабораторные исследования	Нечетко-логическая модель
Заключение о направлении в одно из специализированных отделений	Нечетко-логическая модель

Объединение компонентных моделей в соответствии с их взаимосвязями создает композиционную гибридную модель СМТП. Метод нечеткого ситуативного управления позволяет идентифицировать текущую нечеткую ситуацию, учесть специфику и различные стратегии управления в зависимости от складывающейся ситуации. Ключевой процедурой в методе нечеткого ситуативного управления является нечеткий логический вывод, который представляет обобщение традиционно дедуктивного вывода *modus ponens*. Недостаточная полнота дедукции компенсируется абдуктивным выводом. Логический вывод основан на одношаговой или многошаговой процедуре определения максимальной степени сходства текущей нечеткой ситуации с ситуациями, принятыми за эталонные, в соответствии с которыми принимаются решения или диагностические заключения. Решения, выдаваемые в результате вывода, определяют переход между состояниями пациента. Фрагмент системы ситуационного управления лечением пациента приведен ниже на рис. 11.

В работе [25] проводится исследование почерка пациентов после инсульта в процессе их реабилитации. Идентификация почерка осуществляется с использованием нескольких типов классификаторов. Целью исследования является выбор классификатора, обеспечивающего наилучшую оценку мелкой моторики пациента в период его реабилитации. В качестве классификаторов выступают такие модели, как *k*-ближайших соседей (KNN), метод опорных векторов (SVC), дерево решений (DT) и наивный байесовский классификатор (NB).

Динамическими объектами классификации являются подписи. Динамическое распознавание подписи основано на анализе нескольких характеристик почерка, таких как параметры движения, давление, азимут и угол наклона пера в определенные моменты времени, а также скорость и ускорение вышеперечисленных величин. Для распознавания подписи в базу данных записываются следующие параметры: скорость (общая, горизонтальная, вертикальная), ускорение (общее, горизонтальное, вертикальное), рывок (общий, горизонтальный, вертикальный), корреляция Спирмена (давления и скоростей, давления и ускорения), количество экстремумов (давление, скорость, ускорение). В общей сложности извлекается 45 параметров. Для анализа полученных значений создаются графики зависимости скорости от времени для двух классов (до инсульта – *a*, и после инсульта – *б*) (рис. 12).

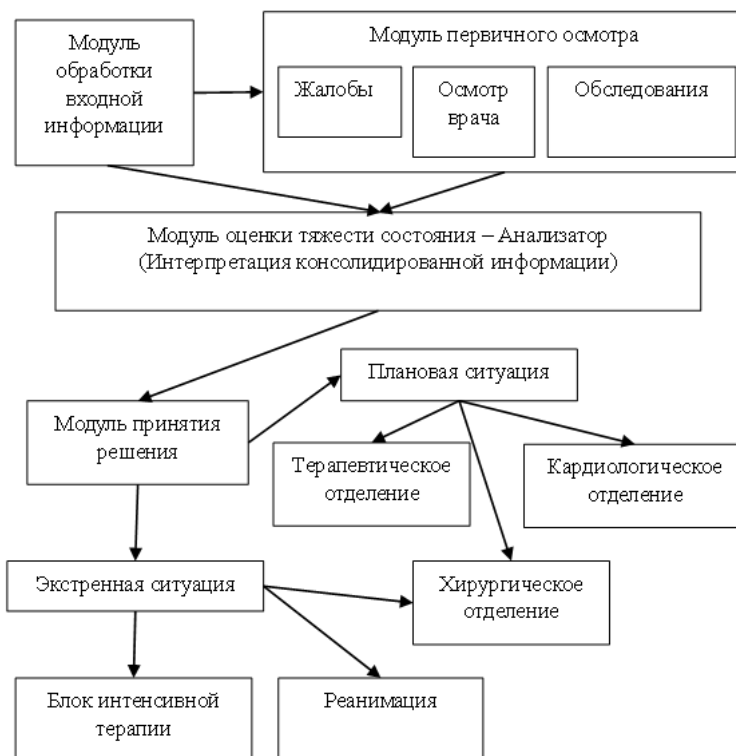


Рис. 11. Фрагмент системы ситуационного управления (блок «Приемное отделение»)




Рис. 12. График вертикальной скорости

На обоих графиках заметны резкие скачки, определяющие переход от одного элемента изображения к другому. Также видно, что график экземпляра подписи слева проходит плавно, без рывков. Справа видно множество колебаний, так как пациенты, проходящие реабилитацию после инсульта, имеют нарушения мелкомоторных движений.

Авторы статьи делают вывод, что лучшим классификатором является модель на основе сиамской нейронной сети. Для обучения нейросетевой модели авторы предлагают ансамблевый метод.

Работа [26] посвящена анализу нового класса и метода построения прогностических моделей для решения задач прогнозирования неблагоприятных событий и их применения в клинической практике.

Основным недостатком существующих моделей прогнозирования в клинической практике является их плохая интерпретируемость, что вызывает недоверие врачей к генерируемым заключениям.

Для решения проблемы авторы используют технологию объяснимого искусственного интеллекта, основанную на деревьях решений (ДР). В статье предложен новый класс прогностических моделей на основе объединения метода аддитивного объяснения Шепли, с помощью которого удается оценить степень влияния предикторов на конечную точку, и дерева решений, в структуру которого включены в качестве новых признаков факторы риска (ФР), полученные с помощью многоуровневой категоризации предикторов, имеющих наибольшую предсказательную ценность.

Новая гибридная модель позволяет модифицировать ДР, обеспечивая, с одной стороны, прозрачность принимаемого решения, а с другой – высокую эффективность модели, что объясняется использованием новых параметров, извлеченных из клинических данных в процессе выделения ФР. Процесс построения дерева решений представляет собой рекурсивный алгоритм разделения набора данных с помощью оптимальных правил. Он разбивает данные, выбирая наилучший порог отсечения, и рекурсивно строит дерево решения, обеспечивая наибольший прирост информации. Важной отличительной особенностью метода является то, что в процедуре разделения данных поиск порогов осуществляется не по уникальным значениям переменных, а из перечня ранее выделенных ФР. Для определения оптимального правила используют критерий прироста информации (энтропийный критерий) и индекс Джини, оценивающие качество разделения данных с учетом обоих классов:

$$\text{Gain}(A') = - \sum_{j=1}^n P_j(A) \cdot \log(P_j(A)) + \sum_{j=1}^n P_j(A') \cdot \log(P_j(A')),$$

где P_j – вероятность i -го класса в наборе данных; A' – подмножество данных, полученное с помощью правила; A – общий набор данных; n – количество прогнозируемых классов;

$$\text{Gini}(A') = 1 - \sum_{j=1}^n P_j(A')^2,$$

где P_j – вероятность i -го класса в наборе данных; A' – подмножество данных, полученное с помощью правила; A – общий набор данных; n – количество прогнозируемых классов.

В связи с тем, что в процессе построения дерева решений при разделении данных в узле образуются два подмножества, метрики качества усредняются с учетом масштаба подмножеств:

$$\text{Mean}(\text{Met}(A')) = (\text{len}(A_t)/\text{len}(A) \cdot \text{Met}(A_t) + \text{len}(A_f)/\text{len}(A) \cdot \text{Met}(A_f)) / 2,$$

где len – количество записей в наборе данных; A_t – подмножество данных, удовлетворяющих правилу; A_f – подмножество данных, не удовлетворяющих правилу; A – общий набор данных; Met – метрика качества разделения набора данных.

Разработанное на основе предикторной модели модифицированное ДР обеспечивает возможность интерпретации прогнозов за счет извлечения продукционных правил из ДР. В статье предикторная модель выступает в качестве прогностической модели внутригоспитальной летальности (ВГЛ) после чрескожного коронарного вмешательства (ЧКВ). Извлеченные из ДР правила позволяют определить степень риска ВГЛ и принять необходимые решения по корректировке лечения.

Эксперименты, проведенные авторами на данных пациентов с инфарктом миокарда с подъемом сегмента ST, которым выполнялось ЧКВ, показали, что разработанная прогностическая модель демонстрирует более высокую точность по сравнению с используемым в настоящее время методом CART и позволяет получать хорошо интерпретируемые результаты прогноза.

В статье [27] также рассматривается новый класс прогностических моделей на основе дооперационных предикторов для прогнозирования послеоперационной фибрилляции предсердий (ПоФП) у больных ишемической болезнью сердца после коронарного шунтирования. Прогностические модели разработаны методами многофакторной логистической регрессии, случайного леса и стохастического градиентного бустинга. Дихотомизация предикторов выполнялась методами поиска на сетке оптимальных точек отсечения, расчета центроидов и аддитивного объяснения Шепли (SHAP).

Метод Шепли позволяет выделить пороги, на которых функция влияния предиктора на конечную точку демонстрировала сингулярность, что может наблюдаться несколько раз в диапазоне изменения значений непрерывного признака. Для выполнения многоуровневой категоризации авторы объединяли все пороговые значения, выделенные с помощью дихотомизации показателей различными методами, в том числе по методу SHAP. При этом близкие пороговые значения объединились в одно путем

усреднения. Метод центроидов предполагал использование медианы анализируемых признаков в группах сравнения, с помощью которых выделяли четыре категории для каждого показателя. Для оценки степени влияния показателей на конечную точку также применяли метод Шепли.

На основе многоуровневых предикторов авторы разработали четыре типа прогностических моделей ПоФП. Результаты экспериментов по оценке точности прогностических моделей ПоФП приведены в табл. 4.

Таблица 4

Оценка точности прогностических моделей ПоФП на основе предикторов с многоуровневой категоризацией

Метрики	Многоуровневый SHAP	Мультиметрическая категоризация	Медианы групп и центроид	Квартили
AUC	0.795 [0.77; 0.82]	0.802 [0.78; 0.82]	0.7 [0.67; 0.77]	0.66 [0.63; 0.69]
Sen	0.735 [0.67; 0.78]	0.741 [0.7; 0.78]	0.65 [0.61; 0.69]	0.6 [0.55; 0.65]
Spec	0.71 [0.688; 0.73]	0.713 [0.69; 0.73]	0.652 [0.63; 0.68]	0.618 [0.58; 0.66]
F-score	0.503 [0.47; 0.54]	0.507 [0.48; 0.53]	0.422 [0.4; 0.44]	0.31 [0.29; 0.34]

Лучшие прогностические свойства демонстрировала модель с предикторами, выделенными методом мультиметрической категоризации.

В работе [28] рассматривается актуальная проблема отсутствия эффективных инструментов для экспресс-определения профессиональной предрасположенности пользователей на основе анализа их профилей в социальных сетях. Цель данного исследования заключается в изучении возможности проведения профориентации с использованием многофункциональной системы в виде приложения для платформы VK Mini Apps, способной автоматически анализировать профили пользователей социальной сети «ВКонтакте», которая содержит данные о тематике подписок пользователей.

В качестве методики для определения профессионального типа личности авторы использовали типизацию, разработанную системой Holland – RIASEC codes. Набор данных, содержащий результаты психологического тестирования и ID пользователей, был получен при помощи приложения «Психологические тесты». В статье также разработан программный модуль для асинхронной выгрузки тематик групп пользователей. На вход модулю подается список ID в виде csv-файла, а по результатам работы генерируется файл, содержащий ID, идентифицирующий респондента, пол пользователя и столбец со списком тематик вида (тематика: количество групп с такой тематикой). Также в ходе предобработки из набора данных исключаются все строки, содержащие только нули (т. е. те пользователи, которые не подписаны ни на одну группу). После этого данные обезличиваются и нормализуются. Программа разработана на языке Python с использованием библиотек scikit-learn, numpy, asyncio, pandas.

В результате набор данных представляется в виде множества:

$$U = \left\{ \left(u_i^{subject}, sex_i, type_i \right), i = \overline{1, n} \right\},$$

где n – число пользователей, $u_i^{subject}$ – нормализованный вектор признаков, характеризующий тематику подписок; sex_i – пол пользователя, указанный в социальной сети «ВКонтакте»; $type_i$ – целевой вектор мультиклассовой классификации.

Пример анализируемых данных представлен в табл. 5.

Таблица 5

Пример анализируемых данных

	Автомобили	...	Электроника	Юмор	Языки	Пол	target
0	0.0827	...	0.0000	0.1654	0.0000	1	I
1	0.0000	...	0.0000	0.9625	0.0201	2	I
2	0.0089	...	0.0089	0.3917	0.0356	1	S
3	0.0000	...	0.0000	0.8939	0.0043	2	C
...

Научная значимость исследования, по мнению авторов, заключается в идентификации взаимосвязей между поведенческими паттернами в социальных сетях и психологическими особенностями в срезе профессионального самоопределения.

Помимо вышеперечисленных докладов в секции была представлена работа [29], в которой описан классификатор на основе нейронных сетей для определения речевого состояния пациента.

5 Неклассические логики и правдоподобный вывод

В данной секции было представлено немного докладов, однако все они затрагивали фундаментальные проблемы ИИ, касающиеся моделирования логических рассуждений и их применения в интеллектуальных системах поддержки принятия решений (ИСППР).

В работе [30] рассматриваются темпоральные логики ветвящегося времени и их практическое использование в составе современных распределенных ИСППР реального времени.

Для построения темпоральной логики ветвящегося времени, ориентированной на применение в ИСППР реального времени, предлагается подход на основе согласования ограничений. Реализация алгоритма вывода основывается на решении задачи согласования темпоральных ограничений (ЗСТО). Формально ЗСТО определяется набором $Z = (V, D, BTR, C)$, где $V = \{V_1, V_2, \dots, V_m\}$ – конечное множество темпоральных переменных; D – область значений темпоральных переменных; $BTR = \{r_1, r_2, \dots, r_n\}$ – конечное множество бинарных темпоральных ограничений, объединение которых является универсальным ограничением U ; $C = \{C_{ij} \mid C_{ij} = \{r_1, \dots, r_k\}; k > 0; r_1, \dots, r_k \in BTR; i, j \leq m\}$ – конечное множество ограничений, где C_{ij} – ограничение над темпоральными переменными V_i и V_j , интерпретируемое как $(V_i, r_1, V_j) \vee \dots \vee (V_i, r_k, V_j)$.

ЗСТО называется *единичной* ЗСТО, если и только если в множество C входят только точные ограничения. ЗСТО имеет решение, если существуют такие значения переменных V_i , что выполняются ограничения из множества C . Если такое означивание построить нельзя, то ЗСВО является *несогласованной*. Если ЗСТО имеет хотя бы одно решение, то ее называют *согласованной*.

Над темпоральными ограничениями определяются следующие операции: *инвертирование* (\sim): $\sim(r_1, \dots, r_k) = (\sim r_1, \dots, \sim r_k)$; *пересечение*: $S \cap T = \{r \mid r \in S, r \in T\}$; *композиция*: $T \bullet S = \{t_1, \dots, t_k\} \bullet \{s_1, \dots, s_q\} = \{t_1 \bullet s_1, t_1 \bullet s_2, \dots, t_k \bullet s_q\}$.

Множество всех возможных типов бинарных темпоральных ограничений состоит из $2|BTR|$ элементов, замкнутых относительно операций \sim, \cap, \bullet , и образует алгебру темпоральных ограничений.

Считается, что ограничение типа r_i сильнее ограничения типа r_j и записывается $r_i \rightarrow r_j$, если и только если из r_i следует r_j , но не его противоречие. Например, ограничение типа «<» сильнее, чем ограничение типа \neq , так как из первого следует второе.

Ограничение C_{ij} выполнимо для переменных V_i и V_j , если и только если существует хотя бы одно решение ЗСТО, в котором C_{ij} является ограничением для этих переменных. Минимальным ограничением C_{ij}^{\min} называется множество, состоящее только из выполнимых ограничений для V_i и V_j . ЗСТО называется *минимальной*, если все ее ограничения минимальны (т. е. из ограничения исключаются компоненты, не входящие ни в одно решение). Для любой ЗСТО всегда можно осуществить переход к эквивалентной минимальной ЗСТО или показать несогласованность ограничений.

Ветвящаяся ЗСТО (ВЗСТО) определяется как множество альтернативных сценариев S_i , унаследованных от одного начального сценария S_0 : $VZ = \{S_i\}$, где $S_i = (V_i, C_i, S_j)$ – сценарий, $i = 0, 1, \dots$, $S_0 = (V_0, D, BTR, C_0)$ – единичная ЗСТО, интерпретируемая как начальный сценарий; $S_i (i > 0)$ – наследуемый сценарий, который расширяет множество переменных V_j и множество единичных ограничений C_j сценария $S_j, j < i$, множествами V_i и C_i соответственно; D – область определения переменных (множество целых чисел), BTR – множество базовых ограничений.

На каждой ветви ВЗСТО можно определить задачи поиска минимального представления и проверки согласованности, т. е. можно говорить о согласованном или несогласованном сценарии и сценарии в минимальном представлении. Сценарий, для которого не существует наследуемых сценариев, называется *терминальным* сценарием.

Для ВЗСТО определяются следующие подзадачи: *проверка согласованности* – проверка существования как минимум одного терминального согласованного сценария $S_i \in VZ$; *проверка истинности* каких-либо утверждений для конкретного терминального сценария; *преобразование* всех ЗСВО, соответствующих согласованным сценариям, к минимальному виду; *проверка истинности* каких-либо утверждений для всех терминальных сценариев или хотя бы для одного терминального сценария.

В завершение работы [30] авторы приводят алгоритмы решения задач для ВЗСТО, построенные на основе парадигмы согласования временных ограничений, с использованием ряда улучшений и эвристик для алгоритмов вывода. Предложенные эвристики существенно снижают алгоритмическую сложность процедур вывода.

В работе [31] исследуется задача выявления причинно-следственных зависимостей в данных с использованием логических средств и методов теории вероятностей.

Центральным компонентом прикладных ИИ-систем является их процедурный «инструментарий» – проблемно ориентированные математические модели, методы и алгоритмы, способные отразить как общие принципы интеллектуального анализа данных, так и специфику конкретных областей приложения. Среди такого рода «инструментов» анализа данных и поддержки принятия решений особое место отводится средствам восстановления причинно-следственных связей, неявным образом представленных в обрабатываемых эмпирических данных. Известно, что при высокой частоте встречаемости причинно-следственных связей частотные характеристики позволяют восстанавливать эти зависимости. В данной работе рассматривается вероятностная схема, позволяющая описать редкую встречаемость причинно-следственных связей.

Рассматривается простой случай, когда исходные данные представляют случайную последовательность свойств из конечного множества $A_N = \{x_1, \dots, x_N\}$. Случайность определяется с помощью полиномиальной схемы из M испытаний с известными вероятностями $p_k = \frac{1}{N}$, $k = 1, \dots, N$.

Построенную модель авторы называют информационным пространством $IS1$. Помимо $IS1$, авторы вводят еще два ресурса – $IS2$ и $IS3$, где $IS2$ представляет множество свойств $B_N = \{y_1, \dots, y_N\}$, а $IS3$ – множество свойств $C_N = \{z_1, \dots, z_N\}$. В $IS2$ и $IS3$ также определены равновероятные полиномиальные схемы длины M . Считается, что каждая вероятностная схема вырабатывает очередное свойство синхронно.

В рассматриваемой схеме причинно-следственной связи следствие может появиться не далее чем через t шагов от появления причины в $IS1$. Для простоты полагается $t = 0$.

1 Схема « $x \rightarrow y$ & $x \rightarrow z$ » возникает, когда у свойства x есть два следствия – y и z .

2 Схема « $x \rightarrow y$ & $y \rightarrow z$ » определяется как последовательность причинно-следственных связей: x влечет появление y , и y влечет появление z . Эта схема также называется транзитивной причиной x для следствия z .

Предложенный метод выполняется за два шага в предположении неизвестности ни причины, ни следствия. Сначала реализуются синхронно три полиномиальные схемы в $IS1$, $IS2$ и $IS3$, а затем в $IS2$ и $IS3$ из появившихся в последовательности $IS1$ причин строятся их следствия.

В работе авторы демонстрируют некоторые возможности использования разработанного метода в прикладных системах ИИ для выявления зависимостей причинно-следственного характера. В ситуациях, когда доказательства дедуктивного характера имеют ограниченную применимость объяснения, формируемые на базе восстанавливаемых из анализируемых данных каузальных зависимостей, могут быть использованы как инструмент повышения доверия к результатам работы систем ИИ.

Помимо рассмотренных выше двух работ в секции неклассических логик интерес вызвала работа [32], направленная на разработку нового подхода, который логическими средствами реализует правдоподобные рассуждения для индуктивного порождения причинно-следственных зависимостей в ограниченных наборах данных. Предлагаемый подход базируется на эмпирической индукции, представленной в виде расширений индуктивных методов Д. С. Милля. В статье показывается возможность применения разработанного метода в ряде критических областей – безопасности, транспорта, медицины, где требуется интерпретируемость и объяснимость работы систем ИИ.

Заключение

В обзорной статье выполнен краткий анализ работ, представленных на конференции ПТИ'24. Рассмотрены основные направления теоретических и прикладных исследований в области современных интеллектуальных технологий. Отличительной чертой докладов в 2024 г. стало большое разнообразие способов применения современных информационных и интеллектуальных технологий в различных областях промышленности, медицины, социальной сферы, естественных наук. Традиционно большую часть докладов составили исследования, посвященные применению ИИ и машинного обучения в технических задачах. Значительная часть докладов, представленных на конференции ПТИ'24, касалась использования нейросетевых технологий по шести основным направлениям: машинное обучение и его

приложения, нейронные и байесовские сети, промышленная интеллектуализация, кибербезопасность в Индустрии 4.0, интеллектуальные технологии в социальных и медицинских науках, неклассические логики и правдоподобный вывод. По каждому из направлений выполнен анализ наиболее интересных докладов для популяризации результатов исследований в области прикладного искусственного интеллекта среди русскоязычной аудитории.

Принятые к публикации доклады будут опубликованы в сборнике трудов конференции ИТИ'24 : *Lecture Notes in Networks and Systems* Vol. 1209 – <https://doi.org/10.1007/978-3-031-77688-5>, 1210 – <https://doi.org/10.1007/978-3-031-77411-9>, LNNS – Springer Science and Business Media Deutschland GmbH, 2025.

Список литературы / References

1 **Konstantinov, A.** An explicit concept-based approach for incorporating expert rules into machine learning models / A. Konstantinov, L. Utkin // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 153–162. – ISBN 978-3-031-77688-5.

2 Synthesis and analysis of porous frame structures images using machine learning methods / A. Poltavskiy, E. Kolomenskaya, G. Beliaevsky [et al.] // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 389–401. – ISBN 978-3-031-77688-5.

3 Impact of Spectral and Meteorological Data Fusion on the Accuracy of Woody Plant Identification Using Deep Machine Learning Methods / A. Alexandrov, P. Dmitriev, A. Dmitrieva [et al.] // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. – Cham : Springer International Publishing, 2024. In 2 vol. Vol. 1. – P. 207–216. – ISBN 978-3-031-77688-5.

4 **Gurov, Y.** Conditional variational autoencoders with fuzzy inference / Y. Gurov, D. Khilkov // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. – Cham : Springer International Publishing, 2024. In 2 vol. Vol. 2. – P. 91–103. – ISBN 978-3-031-77411-9.

5 **Ponomarev, A.** Advanced metrics for the detection problem on perspective transformed images / A. Ponomarev, A. Agafonov, A. Smirnov [et al.] // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 420–430. – ISBN 978-3-031-77688-5.

6 **Narendra, A.** Leveraging single and multi-task reinforcement learning algorithms for autonomous Mobile Aloha Robot / A. Narendra, D. Makarov, A. Panov // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 443–453. – ISBN 978-3-031-77688-5.

7 **Vyatkin, A.** Algebraic Bayesian networks: refinement of the approximate generation of the knowledge pattern canonical representation / A. Vyatkin, M. Abramov // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 466–474. – ISBN 978-3-031-77688-5.

8 **Ilicheva, V. V.** Complexity estimate of logical specifications execution for transport processes prototyping / V. V. Ilicheva, A. N. Guda // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 3–11. – ISBN 978-3-031-77688-5.

9 Planning station operations based on actual station performance obtained “from the wheel” / S. Kovalev, A. Sukhanov, I. Olgezyer, V. Ierusalimov // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 33–42. – ISBN 978-3-031-77688-5.

10 Safety control of the use of technical vision systems on hump humps / K. Kornienko, P. Borovlev, K. Maksimov [et al.] // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 62–69. – ISBN 978-3-031-77688-5.

11 Intelligent approach to solving the problem control over railway cars in the marshalling yard / A. Shulzhenko, A. Sukhanov, M. Butakova, V. Ierusalimov // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 62–69. – ISBN 978-3-031-77688-5.

- 12 **Bulavin, Yu.** Leveraging deep reinforcement learning for reducing longitudinal train forces in railway systems / Yu. Bulavin, O. Ignatieva // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. In 2 vol. Vol. 1. – P. 118–130. – ISBN 978-3-031-77688-5.
- 13 **Dorodnykh, N.** Using state transition diagrams for automated knowledge base construction / N. Dorodnykh, A. Yurin // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 21–32. – ISBN 978-3-031-77688-5.
- 14 **Gladkov, L.** The development of a method for managing traffic flows based on an agent-based approach / L. Gladkov, G. Veselov, D. Elkin // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 108–117. – ISBN 978-3-031-77688-5.
- 15 **Kucherov, S.** Method for intellectualization of interaction between a technical system and a user in the natural language of a domain / S. Kucherov, Y. Rogozov, A. Sviridov, A. Borisov, Y. Lipko // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. – Cham : Springer International Publishing, 2024. In 2 vol. Vol. 1. – P. 43–51. – ISBN 978-3-031-77688-5.
- 16 **Gribova, V.** SMART standards for industry / V. Gribova, E. Shalfeeva // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 1. – Cham : Springer International Publishing, 2024. – P. 70–82. – ISBN 978-3-031-77688-5.
- 17 **Zelichenok, I.** Detection of botnets using artificial intelligence methods / I. Zelichenok, K. Zhernova, A. Chechulin, L. Vitkova // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 15–24. – ISBN 978-3-031-77411-9.
- 18 **Mogilny, A.** Framework for the development of anomaly detection and classification models for cyber-physical systems / A. Mogilny, E. Basan, A. Basan // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 57–68. – ISBN 978-3-031-77411-9.
- 19 Mutual information based ensemble anomaly detection strategy for cyber-physical systems / Z. Ahmad, A. Petrovski, I. Kotenko [et al.] // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 69–78. – ISBN 978-3-031-77411-9.
- 20 **Vulfin, A.** System for detecting anomalies in information security logs / A. Vulfin, P. Lozhnikov, A. Sulavko [et al.] // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 35–45. – ISBN 978-3-031-77411-9.
- 21 **Kotenko, I.** A statistical approach to evaluation and selection of wavelets for detecting computer attacks / I. Kotenko, I. Saenko, P. Bortniker // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 3–14. – ISBN 978-3-031-77411-9.
- 22 **Zhou, D.** FedDW: Leveraging dataset distillation for black-box watermarking in federated learning models / Dawei Zhou, Jialiang Peng // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 46–56. – ISBN 978-3-031-77411-9.
- 23 **Petrovski, A.** Insider threat detection within operational technologies using digital twins / A. Petrovski, I. Kotenko, M. Arifeen [et al.] // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 25–34. – ISBN 978-3-031-77411-9.
- 24 **Kobriniskii, B.** Fuzzy situational control at the stages of the medical-and-technological process: problems and possible solutions / B. Kobriniskii // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 312–323. – ISBN 978-3-031-77688-5.
- 25 Formation of a dataset for assessing fine motor skills in handwriting after a stroke and an example of its application / E. Kostyuchenko, V. Ezhova, D. Koshechko, S. Fominykh // *Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference*. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 205–213. – ISBN 978-3-031-77411-9.

26 Predicting atrial fibrillation in patients with ischemic heart disease based on multilevel categorization / K. Shakhgelyan, B. Geltser, N. Kuksin [et al.] // Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 225–235. – ISBN 978-3-031-77411-9.

27 Predicting atrial fibrillation in patients with ischemic heart disease based on multilevel categorization / K. Shakhgelyan, V. Rubleb, N. Kuksin [et al.] // Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 225–235. – ISBN 978-3-031-77411-9.

28 **Chekalev, A.** Community theme analyser : Predicting career guidance in online social networks / A. Chekalev, A. Khlobystova, M. Abramov // Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 153–162. – ISBN 978-3-031-77411-9.

29 Classifier based on neural networks to determine the patient's speech state / D. Novokhrestova, S. Tomilina, P. Laptev, E. Kostyuchenko // Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference. – Cham : Springer International Publishing, 2024. – P. 236–244. In 2 vol. Vol. 2. – ISBN 978-3-031-77411-9.

30 **Eremeev, A.** Research and development of a temporal model of branching time for the Intelligent systems of real-time / A. Eremeev, I. Kurilenko, N. Filinov // Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 247–259. – ISBN 978-3-031-77411-9.

31 Probabilistic models for detection of causal relationships in data sequences / M. I. Zabezhailo, A. A. Grusho, N. A. Grusho, E. E. Timonina // Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference. In 2 vol. Vol. 2. – Cham : Springer International Publishing, 2024. – P. 271–279. – ISBN 978-3-031-77411-9.

32 **Mikheyenkova, M.** Causal relationships as a basis for diagnosis and decision making / M. Mikheyenkova // Intelligent Information Technologies for Industry (IITI'24) : Proceedings of the Eighth International Scientific Conference. – Cham : Springer International Publishing, 2024. In 2 vol. Vol. 2. – P. 260–270. – ISBN 978-3-031-77411-9.

S. M. Kovalev, M. A. Butakova, A. N. Guda, I. A. Olgezyer, A. V. Sukhanov

REVIEW OF THE PROCEEDINGS OF THE IITI'24 CONFERENCE

Abstract. This article provides a brief summary of the most interesting reports of the 8th International Scientific Conference “Intelligent Information Technologies in Engineering and Production” (IITI'24), organized by the Federal State Budgetary Educational Institution of Higher Education RSTU, JSC “NIIAS” and Harbin Polytechnic University (China) with the support of the Russian Association of Artificial Intelligence, which was held from November 1 to 7, 2024 in China (Shanghai and Harbin). The opening of the IITI'24 conference took place in Shanghai, as part of the CIEP 2024 International Experience Exchange Forum at the invitation of the Ministry of Human Resources and Social Security of China, which was attended by over 2,000 scientists from more than 120 countries.

The aim of IITI'24 was to share the best practices in fundamental and applied research in the field of artificial intelligence, information technology and automation, as well as to develop international contacts. Particular attention was paid to advanced intelligent technologies and their use in various fields of industry, including railway transport.

Keywords: intelligent information technologies, artificial intelligence, industrial intellectualization, Industry 4.0.

For citation: Review of the proceedings of the IITI'24 conference / S. M. Kovalev, M. A. Butakova, A. N. Guda [et al.] // Vestnik Rostovskogo Gosudarstvennogo Universiteta Putey Soobshcheniya. – 2024. – No. 4. – P. 107–133. – DOI 10.46973/0201-727X_2024_4_107.

Сведения об авторах**Ковалев Сергей Михайлович**

Ростовский филиал АО «Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте» (РостФ НИИАС),
научный руководитель

Ростовский государственный университет путей сообщения (РГУПС),
кафедра «Автоматика и телемеханика на железнодорожном транспорте»,
доктор технических наук, профессор,
e-mail: ksm@rfniias.ru

Бутакова Мария Александровна

Ростовский филиал АО «Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте» (РостФ НИИАС),
главный научный сотрудник

Ростовский государственный университет путей сообщения (РГУПС),
кафедра «Информатика»,
доктор технических наук, профессор,
e-mail: m.butakova@vniias.ru

Гуда Александр Николаевич

Ростовский государственный университет путей сообщения (РГУПС),
кафедра «Информатика»,
доктор технических наук, профессор,
заведующий кафедрой, проректор по научной работе,
e-mail: guda@rgups.ru

Ольгейзер Иван Александрович

Ростовский филиал АО «Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте» (РостФ НИИАС),
первый заместитель директора филиала

Ростовский государственный университет путей сообщения (РГУПС),
кафедра «Вычислительная техника и автоматизированные системы управления»,
кандидат технических наук, доцент,
e-mail: olgeyzer@rfniias.ru

Information about the authors**Kovalev Sergey Mikhailovich**

Rostov branch of JSC «Scientific Research and Design Institute of Information, Automation and Communications in Railway Transport» (RostF NIIAS),
Scientific Supervisor

Rostov State Transport University (RSTU),
Chair «Automation and Telemechanics in Railway Transport»,
Doctor of Engineering Sciences,
Professor,
e-mail: ksm@rfniias.ru

Butakova Maria Aleksandrovna

Rostov branch of JSC «Scientific Research and Design Institute of Informatization, Automation and Communications in Railway Transport» (RostF NIIAS),
Chief Researcher

Rostov State Transport University (RSTU),
Chair «Computer Science»,
Doctor of Engineering Sciences,
Professor,
e-mail: m.butakova@vniias.ru

Guda Alexander Nikolayevich

Rostov State Transport University (RSTU),
Chair «Computer Science»,
Doctor of Engineering Sciences,
Professor
Head of the Chair, Vice Rector for Scientific Research,
e-mail: guda@rgups.ru

Olgeyzer Ivan Alexandrovich

Rostov branch of JSC «Scientific Research and Design Institute of Informatization, Automation and Communications in Railway Transport» (RostF NIIAS)
First Deputy Director of the Branch

Rostov State Transport University (RSTU),
Chair «Computer Engineering and Automated Control Systems»,
Candidate of Engineering Sciences,
Associate Professor,
e-mail: olgeyzer@rfniias.ru

Суханов Андрей Валерьевич

Ростовский филиал АО «Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте» (РостФ НИИАС),
заместитель начальника отделения интеллектуальных информационных технологий цифровой станции

Ростовский государственный университет путей сообщения (РГУПС),
кафедра «Вычислительная техника и автоматизированные системы управления»,
кандидат технических наук, доцент,
e-mail: a.suhanov@vniias.ru

Sukhanov Andrey Valeryevich

Rostov branch of JSC «Scientific Research and Design Institute of Informatization, Au-tomation and Communications in Railway Transport»
Deputy Head of the Department of Intelligent Information Technologies of the Digital Station

Rostov State Transport University (RSTU),
Chair «Computer Engineering and Automated Control Systems»,
Candidate of Engineering Sciences,
Associate Professor,
email: a.suhanov@vniias.ru