

Industrial Transport of Kazakhstan
ISSN 1814-5787 (print)
ISSN 3006-0273 (online)
Vol. 21. Is. 3. Number 83 (2024). Pp. 95–109
Journal homepage: <https://prom.mtgu.edu.kz>
<https://doi.org/10.58420/ptk/2024.83.03.007>
UDC 656.2

INTELLECTUALIZATION OF MANAGERIAL DECISION SUPPORT IN EMERGENCY SITUATIONS IN RAILWAY TRANSPORTATION

R.N. Moldasheva

Atyrau University named after Kh. Dosmukhamedov, Kazakhstan.

E-mail: raushan85_07@mail.ru

Moldasheva Raushan Nurkozhaevna — Educational Program 8D06101 Big Data Analytics. Atyrau University named after Kh. Dosmukhamedov, PhD, Associate Professor
E-mail: raushan85_07@mail.ru, <https://orcid.org/0000-0002-4570-0487>.

© R.N. Moldasheva

Abstract. This study focuses on the intellectualization of decision-making support for emergency situations (ES) on railway transport. The relevance of the research is determined by the need to improve the efficiency and accuracy of decision-makers' actions, especially in weakly formalized and rare ES scenarios. The aim of the study is to develop methods and algorithms for intellectualization that reproduce expert actions using artificial neural networks (ANNs). The objectives include: analyzing existing ES classification methods; formalizing expert knowledge; developing and training ANNs based on decision-makers' experience; and evaluating the effectiveness of the proposed approach through practical examples. The results indicate that using ANNs allows accurate classification of different types of ES, predicting the scale of consequences, and generating recommended actions for decision-makers. The proposed ANN training method enables system adaptation to the specifics of individual railway stations, including rare and weakly formalized situations. The study concludes that intellectualization of decision-making support enhances emergency management efficiency, reduces material and human costs, and opens prospects for further research and implementation of decision support systems on railway transport.

Keywords: emergency situations, railway transport, intellectualization, artificial neural networks, expert knowledge, decision support

For citation: R.N. Moldasheva. Simulation Intellectualization of Managerial Decision Support in Emergency Situations in Railway Transportation//Industrial Transport of Kazakhstan. 2024. Vol. 21. No. 83. Pp. 95–109. (In Russ.). <https://doi.org/10.58420/ptk/2024.83.03.007>

Conflict of interest: The authors declare that there is no conflict of interest.

ТЕМІРЖОЛ КӨЛІГІНДЕГІ ТӨТЕНШЕ ЖАҒДАЙЛАР ЖАҒДАЙЫНДА БАСҚАРУШЫЛЫҚ ШЕШІМДЕРДІ ҚОЛДАУ ЖҮЙЕСІН ЗИЯТТАНДЫРУ

Р.Н. Молдашева

Х.Досмұхамедов атындағы Атырау университеті, Атырау, Қазақстан.

E-mail: raushan85_07@mail.ru

Молдашева Раушан Нұрқожаевна — 8D06101 «Үлкен деректер аналитикасы» білім беру бағдарламасы. Х. Досмұхамедов атындағы Атырау университеті қауымдастырылған профессоры, PhD



E-mail: raushan85_07@mail.ru, <https://orcid.org/0000-0002-4570-0487>.

© Р.Н. Молдашева

Аннотация. Бұл жұмыста теміржол көлігінде төтенше жағдайларда (ТЖ) басқару шешімдерін қабылдауды интеллектуалды қолдау мәселесі қарастырылады. Зерттеудің өзектілігі — шешім қабылдаушылардың әрекеттерін жылдам әрі дәл орындауын қамтамасыз ету қажеттілігі, әсіресе сирек кездесетін және аз формалданған ТЖ жағдайларында. Зерттеудің мақсаты — жасанды нейрондық желілерді (ЖНЖ) пайдаланып, эксперттердің әрекеттерін қайта өндіретін интеллектуалдандыру әдістері мен алгоритмдерін әзірлеу. Мақсатқа жету үшін келесі міндеттер шешілді: ТЖ-ны жіктеудің қазіргі әдістерін талдау; эксперттік білімді формализациялау; ЖНЖ-ны шешім қабылдаушылардың тәжірибесі негізінде әзірлеу және оқыту; ұсынылған тәсілдің тиімділігін тәжірибелік мысалдар арқылы бағалау. Зерттеу нәтижесі бойынша ЖНЖ әртүрлі ТЖ түрлерін дұрыс жіктеуге, салдардың ауқымын болжауға және шешім қабылдаушыларға ұсынылатын әрекеттерді қалыптастыруға мүмкіндік береді. Дамытылған ЖНЖ оқыту әдісі жүйені нақты теміржол станциясының ерекшеліктеріне бейімдеуге, соның ішінде сирек және аз формалданған жағдайларға мүмкіндік береді. Зерттеудің қорытындысы — басқару шешімдерін интеллектуалдандыру төтенше жағдайларды тиімді шешуді арттырады, материалдық және адами шығындарды азайтады және теміржол көлігінде шешім қабылдауды қолдау жүйелерін енгізуге әрі қарайғы зерттеулер үшін перспективалар ашады.

Түйін сөздер: төтенше жағдайлар, теміржол көлігі, интеллектуализация, жасанды нейрондық желілер, эксперттік білім, шешім қабылдауды қолдау

Дәйексөздер үшін: Р.Н. Молдашева. Теміржол көлігіндегі төтенше жағдайлар жағдайында басқарушылық шешімдерді қолдау жүйесін зияттандыру//Қазақстан өндіріс көлігі. 2024. Том. 21. № 83. 95–109 бет. (Орыс. тіл.). <https://doi.org/10.58420/ptk/2024.83.03.007>

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

ИНТЕЛЛЕКТУАЛИЗАЦИЯ ПОДДЕРЖКИ ПРИНЯТИЯ УПРАВЛЕНЧЕСКИХ РЕШЕНИЙ ПРИ ВОЗНИКНОВЕНИИ ЧС НА ЖЕЛЕЗНОДОРОЖНОМ ТРАНСПОРТЕ

Р.Н. Молдашева

Атырауский университет имени Х. Досмухамедова, Атырау, Казахстан.

E-mail: raushan85_07@mail.ru

Молдашева Раушан Нуркожаевна — образовательная программа 8D06101 «Аналитика больших данных». Атырауский университет имени Х. Досмухамедова, ассоциированный профессор, PhD

E-mail: raushan85_07@mail.ru, <https://orcid.org/0000-0002-4570-0487>.

© Р.Н. Молдашева

Аннотация. В данной работе рассматривается интеллектуализация поддержки принятия управленческих решений при возникновении чрезвычайных ситуаций (ЧС) на железнодорожном транспорте. Актуальность исследования определяется необходимостью повышения оперативности и точности действий лиц, принимающих решения (ЛПР), особенно в слабоформализуемых и редко встречающихся ситуациях ЧС. Цель исследования заключается в разработке методов и алгоритмов интеллектуализации,



обеспечивающих воспроизведение действий эксперта с помощью искусственных нейронных сетей (ИНС). Для достижения цели решались следующие задачи: анализ существующих методов классификации ЧС; формализация экспертных знаний; разработка и обучение ИНС на основе опыта ЛПР; оценка эффективности предложенного подхода на практических примерах. В результате исследования выявлено, что использование ИНС позволяет корректно классифицировать различные типы ЧС, прогнозировать масштаб последствий и формировать рекомендуемые действия ЛПР. Разработанный метод обучения ИНС обеспечивает адаптацию системы к специфике конкретной железнодорожной станции, включая редкие и слабоформализуемые ситуации. Заключение исследования подтверждает, что интеллектуализация поддержки принятия решений повышает эффективность ликвидации ЧС, снижает материальные и людские затраты, а также открывает перспективы дальнейших исследований и внедрения систем поддержки ЛПР на железнодорожном транспорте.

Ключевые слова: ЧС, железнодорожный транспорт, интеллектуализация, искусственные нейронные сети, экспертные знания, поддержка принятия решений

Для цитирования: Р.Н. Молдашева. Интеллектуализация поддержки принятия управленческих решений при возникновении ЧС на железнодорожном транспорте//Промышленный транспорт Казахстана. 2024. Т. 21. No. 83. Стр. 95–109. (На рус.). <https://doi.org/10.58420/ptk/2024.83.03.007>

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Введение

Развитие железнодорожного транспорта в условиях увеличивающегося объема перевозок и роста требований к безопасности создаёт необходимость повышения эффективности управления чрезвычайными ситуациями (ЧС) на объектах инфраструктуры. В современных условиях ЛПР (лицам, принимающим решения) приходится сталкиваться с большим разнообразием аварийных и чрезвычайных ситуаций, включая редкие и сложные случаи, для которых стандартные инструкции и методики могут быть недостаточны (Кульба, 2013: 180–183).

Актуальность исследования определяется тем, что, несмотря на существующие методики управления ЧС, остаются нерешёнными вопросы интеллектуализации поддержки принятия управленческих решений при возникновении редких и слабоформализуемых ситуаций на железнодорожном транспорте (Смирнов, 2024: 1100–1138). Существующие классификационные схемы и подходы к оценке масштаба ЧС, включая определение класса устойчивости приземного слоя атмосферы, имеют значительный разброс результатов и требуют высокой квалификации ЛПР (Цуриков, 2013: 56–65; Callan, 2013: 100–139). Это создаёт потребность в разработке интеллектуальных систем поддержки принятия решений, способных учитывать экспертные знания и слабоформализуемые данные, для уменьшения ошибок и повышения оперативности управления (Васильев, 2000: 100–130).

Объект исследования — процессы принятия управленческих решений при возникновении ЧС на железнодорожном транспорте.

Предмет исследования — интеллектуальные методы поддержки принятия решений ЛПР с использованием экспертных знаний и алгоритмов машинного обучения.

Цель исследования — разработка методов интеллектуализации поддержки принятия управленческих решений при возникновении ЧС на железнодорожном транспорте на основе знаний экспертов и технологий искусственных нейронных сетей.

Задачи исследования:

- Проанализировать существующие подходы к классификации ЧС и оценке их масштаба.

- Выявить особенности использования экспертных знаний ЛПР при возникновении слабоформализуемых ситуаций.

- Исследовать возможности применения искусственных нейронных сетей для моделирования действий экспертов при принятии решений в условиях ЧС.

- Разработать авторский метод обучения ИНС на основе знаний эксперта, обеспечивающий корректную классификацию редких и сложных ситуаций.

Методы исследования включают системный анализ, методы интеллектуализации и искусственного интеллекта, машинное обучение, математическое моделирование и экспертизу данных.

Научная новизна работы заключается в разработке метода обучения ИНС, способного воспроизводить интеллектуальные действия опытного ЛПР при редких и слабоформализуемых чрезвычайных ситуациях, что позволяет существенно повысить оперативность и точность принимаемых решений.

Практическая значимость исследования состоит в возможности внедрения разработанных методов в СППУР для железнодорожного транспорта, что способствует снижению материальных и человеческих потерь, оптимизации задействованных ресурсов и повышению безопасности транспортной системы.

Гипотеза исследования заключается в том, что использование ИНС, обучаемых на знаниях экспертов, позволяет воспроизводить действия ЛПР при возникновении ЧС даже в случаях редких и слабоформализуемых ситуаций, обеспечивая точность и оперативность принятия управленческих решений.

Материалы и методы

Материалом исследования послужили данные о чрезвычайных ситуациях (ЧС), возникших на железнодорожном транспорте, а также сведения о действиях ЛПР, фиксированные в процессе ликвидации последствий ЧС на различных объектах инфраструктуры. Для качественной характеристики материала использовались сведения о типах ЧС (аварии на железнодорожной линии, технологические аварии, аварии с АХОВ и др.), масштабах последствий, числе задействованных ресурсов и степени воздействия на инфраструктуру. Количественно материал исследования включал более 200 случаев возникновения ЧС, зарегистрированных в период с 2013 по 2024 год, а также архивные данные и описания экспертных действий (Кульба, 2013: 180–183; Смирнов, 2024: 1100–1138).

В качестве источников информации использовались:

- научные публикации и монографии по управлению ЧС на железнодорожном транспорте (Цуриков, 2013: 56–65; Васильев, 2000: 100–130);

- архивные материалы предприятий железнодорожного транспорта;

- материалы международных конференций и сборников по интеллектуальным системам управления (Tsurikov, 2013: 226–231);

- описания технологий искусственных нейронных сетей и методов интеллектуализации (Winston, 2020: 115–230; Luger, 2008: 75–85).

Вопросы исследования включали:

- Как обеспечить корректную классификацию чрезвычайных ситуаций, возникающих на железнодорожном транспорте, включая редкие и слабоформализуемые случаи?

- Какие методы интеллектуализации и алгоритмы машинного обучения позволяют моделировать действия опытных ЛПР при возникновении ЧС?

- Как построить обучающую выборку для ИНС на основе знаний экспертов, чтобы минимизировать ошибки при классификации редких ЧС?

Предложенная гипотеза (тезис): использование искусственных нейронных сетей, обученных на базе знаний экспертов, позволяет воспроизводить действия ЛПР при возникновении ЧС с достаточной точностью и оперативностью, включая редко

встречающиеся и слабоформализуемые ситуации.

Этапы исследования:

- Сбор и систематизация данных о ЧС на железнодорожном транспорте, включая архивные материалы и публикации.

- Выявление и классификация типовых и нетиповых ситуаций ЧС, определение критериев масштабности и воздействия (Цуриков, 2013: 56–65; Callan, 2013: 100–139).

- Анализ опыта работы ЛПР, включая опыт экспертов, и выделение слабоформализуемых знаний, важных для принятия управленческих решений (Асанов, 2002: 12–59).

- Разработка модели искусственной нейронной сети для имитации действий ЛПР, включая обучение «с учителем» на основе экспертных данных.

- Тестирование разработанной ИНС на контрольных данных, проверка корректности классификации ЧС и адекватности рекомендаций для ЛПР.

- Сравнительный анализ эффективности ИНС с традиционными методами поддержки принятия решений.

Методы исследования:

- Системный анализ – для изучения структуры процессов принятия решений ЛПР и их взаимодействия с инфраструктурой железнодорожного транспорта;

- Методы классификации и машинного обучения – разработка и обучение ИНС на базе знаний экспертов;

- Математическое моделирование – построение моделей классификации ЧС и оценки масштаба воздействия;

- Экспертные методы – выявление слабоформализуемых знаний ЛПР и формализация их в виде обучающих данных для ИНС (Winston, 2020: 115–230; Luger, 2008: 75–85);

- Статистический анализ – обработка количественных данных о ЧС для проверки достоверности и обоснованности результатов (Смирнов, 2024: 1100–1138).

Использование комбинации качественного и количественного анализа материалов, а также интеграция методов интеллектуализации, машинного обучения и экспертных оценок обеспечивают достоверность полученных выводов и позволяют реализовать новизну подхода — обучение ИНС на основе опыта конкретного эксперта для поддержки принятия управленческих решений при ЧС на железнодорожном транспорте.

Результаты и обсуждение

Большинство интеллектуальных задач, решаемых ЛПР при возникновении ЧС на железнодорожном транспорте, относятся к задачам классификации.

Среди них центральное место можно отвести задаче оценки масштаба возникшей ЧС на основе имеющихся данных. Именно в проведении предварительной оценки масштаба ЧС нуждается ЛПР в первые минуты после получения информации о возникновении ЧС (Кульба, 2013:180–183).

Математическая постановка этой задачи практически идентична ранее приведенной постановке задачи классификации в общем виде. Если принять, что Z – это множество параметров ЧС, которые могут быть получены ЛПР при ее возникновении, а M – множество классов масштаба ЧС, к которым она может быть отнесена и, при этом, существует неизвестная зависимость $z^*: Z \rightarrow M$, значения которой известны только на объектах конечной выборки $Z_i =$

$\{(z_i, m_i)\}$, $i = 1, \dots, k$, то необходимо создать систему $\gamma: Z \rightarrow M$, способную корректно классифицировать произвольную ЧС масштаба $m \in M$.

От успешного решения этой задачи во многом зависит выполнение последующих операций ТП принятия решений при возникновении ЧС. Т.е. ее можно рассматривать как основу принятия управленческих решений. В СППУР это позволяет определять рекомендуемый ЛПР набор действий при возникновении ЧС, как функцию (соответствие)

от масштаба и типа произошедшей ЧС:

$$F(M, T) \rightarrow P,$$

(1)

где M – масштаб ЧС,

T – тип ЧС,

P – рекомендуемый ЛПР набор действий.

При этом в рекомендуемый ЛПР набор действий P входят не только советы по рекомендуемому порядку действий, сформированные на основе действующей НТД, но и другие элементы:

$$(So, Me, In) \square P, \quad (2)$$

где So – советы по рекомендуемому порядку действий, сформированные на основе действующей НТД (фрагменты НТД),

Me – формализованные расчетные методики, соответствующие типу и масштабу ЧС, реализованные в виде компьютерных подпрограмм,

In – сценарии информирования внешних ЛПР о возникновении ЧС (списки информирования и шаблоны типовых сообщений).

Такой подход позволяет абстрагироваться от принципиально различных по своей природе явлений и процессов, сформировавших возникшую ЧС и организовать поддержку принятия решений ЛПР на основе ожидаемого масштаба ЧС. Таким образом, СППУР будет способствовать оперативному решению информационных и расчетных задач на основе полученного решения интеллектуальной задачи классификации ЧС.

Также важной задачей классификации, решаемой ЛПР при возникновении ЧС с АХОВ, является задача определения класса устойчивости приземного слоя атмосферы [58], который оказывает значительное влияние на интенсивность рассеивания примесей в приземном слое воздуха и определяет глубину распространения облака АХОВ, а, следовательно, и масштаб такой ЧС.

По существующим методикам (Цуриков, 2013: 56–65; Callan, 2013: 100–139) ЛПР определяют класс устойчивости атмосферы при помощи таблиц, подставляя в них метеоданные фактической погоды (скорость ветра, уровень облачности, время суток, наличие снежного покрова), которые могут быть получены от метеостанций или путем непосредственного наблюдения. Опытные ЛПР (эксперты) (Асанов, 2002: 12–59) способны определить класс устойчивости атмосферы визуально по внешним признакам.

Однако у большинства ЛПР это может вызвать затруднения, особенно в экстремальных условиях ЧС.

Согласно НТД (Цуриков, 2013: 56–65; Callan, 2013: 100–139), если невозможно точно определить устойчивость атмосферы, то при принятии решений ЛПР должны исходить из ее наихудшего состояния, что ведет к завышенной оценке глубины зоны заражения АХОВ. А следовательно, приводит к необоснованным материальным затратам, преувеличению потребных сил и средств ликвидации ЧС, ошибочному вызову служб на место ЧС, «оголению» других участков и т.д.

Отмечается (Васильев, 2000: 100–130), что используемые классификационные схемы дают значительный разброс при оценке класса устойчивости атмосферы. В более ранних методиках (Цуриков, 2013: 56–65) устойчивость атмосферы характеризовалась тремя состояниями – конвекцией, изотермией, инверсией. Из них инверсия, способствующая сохранению высоких концентраций АХОВ и их распространению, является наиболее неблагоприятной.

В новых документах (Callan, 2013: 100–139) вводится уже шесть классов устойчивости атмосферы (модифицированные классы по Паскуилу) – A, B, C, D, E, F . Наиболее неблагоприятными с точки зрения распространения АХОВ являются классы E и F . Также (Васильев, 2000: 100–130) существует классификация по Тернеру, вводящая 7

классов устойчивости атмосферы. Для характеристики атмосферы возможно использовать и лингвистические переменные (очень неустойчивая, умеренно неустойчивая и т.д.), соответствующие оценкам, обычно используемым ЛПР при принятии решений. Соответствие между классами устойчивости атмосферы приведено в таблице 1.

Задача определения класса устойчивости атмосферы математически формулируется, как задача классификации, где $G = [\text{скорость ветра, уровень облачности, время суток, снежный покров}]$ – множество описаний параметров фактической погоды, $Q = \{A, B, C, D, E, F\}$ – множество классов устойчивости атмосферы. Существует неизвестное отображение $g^*: G \rightarrow Q$, значения которого известны только на объектах конечной выборки $G_j = \{(g_i, q_i), \dots, (g_i, q_i)\}$. Требуется найти алгоритм $\beta: G \rightarrow Q$, способный корректно классифицировать произвольное состояние погоды $g \in G$.

Таблица 1. Качественные соответствия между классами устойчивости и характеристикой атмосферы

| Характеристика атмосферы | Класс устойчивости по Тернеру | Класс устойчивости по Паскуилу | Степень устойчивости атмосферы |
|--------------------------|-------------------------------|--------------------------------|--------------------------------|
| Очень неустойчивая | 1 | A | |
| Умеренно неустойчивая | 2 | B | |
| Слабо неустойчивая | 3 | C | |
| Безразличная | 4 | | |
| Слабо устойчивая | 5 | | |
| Умеренно устойчивая | 6 | E | |
| Очень устойчивая | 7 | F | |

Подобным образом могут быть сформулированы и другие задачи классификации, обычно решаемые ЛПР при возникновении ЧС на железнодорожном транспорте, например, задача выбора подходящего для ликвидации ЧС места остановки железнодорожного состава и т.д.

Ранее указывалось, что при решении таких интеллектуальных задач наблюдается разница между действиями опытных ЛПР (экспертов) и большинства других ЛПР, не успевших приобрести достаточный опыт принятия управленческих решений. Также отмечалось, что даже опытные ЛПР в напряженной обстановке ЧС могут проявить растерянность и не выполнить необходимые действия. Поэтому для успешной поддержки принятия решений следует использовать знания только опытных ЛПР (экспертов), извлеченные и сохраненные в памяти СППУР, которая не растеряется при возникновении ЧС и поможет выполнить необходимые действия.

Под экспертами здесь и далее понимаются ЛПР, способные успешно справляться с решением интеллектуальных задач при возникновении ЧС, обладающие необходимыми специальными знаниями и навыками принятия верных управленческих решений, компетентные в рассматриваемой предметной области. Экспертное знание формируется при практическом решении задач в течение длительного времени. Отмечается (Tsurikov, 2013: 226–231), что ЛПР требуется более 10 лет, чтобы стать опытным экспертом.

При этом также следует иметь в виду, что при решении задач классификации эксперт учитывает специфические условия, присущие конкретной железнодорожной станции, на которой возникла ЧС. Поэтому, для обеспечения массового тиражирования разрабатываемой СППУР в ней должны быть предусмотрены возможности легкой настройки и адаптации на месте ее внедрения, обучения на основе априорных экспертных знаний и информации, полученной в ходе эксплуатации системы.

Интеллектуализацию можно определить, как процесс моделирования и воспроизведения с помощью ЭВМ деятельности человека, связанной с решением интеллектуальных задач (Winston, 2020: 115–230). В работах (Tsurikov, 2013: 226–231; Winston, 2020: 115–230; Luger, 2008: 75–85) отмечается принципиальное различие в подходах к интеллектуализации для хорошо формализуемых предметных областей, к

которым относятся задачи физики и математики, и слабоформализуемых областей, к которым относится большинство ситуаций, объектов и ТП на транспорте, в том числе, и приведенные в этом разделе задачи классификации ЧС.

К особенностям слабоформализуемых предметных областей относят то, что в них определяющими факторами при принятии решений являются профессиональные умения, опыт и интуиция эксперта (слабоформализуемые знания). Основные проблемы извлечения слабоформализуемых экспертных знаний обусловлены тем, что правила, которые удается получить от эксперта в явном виде, охватывают лишь наиболее простые задачи из тех, которые он способен правильно решить, а значительную часть своего профессионального опыта эксперты не могут выразить словесно (вербально) (McCarthy, 2006: 12–14).

Решение указанной проблемы извлечения экспертных знаний в слабоформализуемых предметных областях определяет основные аспекты дальнейшего построения системы. Проблема относится к наиболее сложным, актуальным и до сих пор не решенным в полной мере, являясь «узким местом» при создании систем, основанных на знаниях. Исследования в этом направлении продолжаются (Tsurikov, 2013: 226–231; Luger, 2008: 75–85).

Задача осложняется тем, что в область слабоформализуемых знаний эксперта попадают редко встречающиеся на практике случаи возникновения ЧС. Однако именно в таких ситуациях ЛПП в наибольшей степени нуждается в интеллектуальной поддержке принятия решений со стороны СППУР (Смирнов, 2024: 1100–1138).

Проиллюстрируем это графически, на примере случая двухклассовой классификации линейно сепарабельных ситуаций, когда число классов равняется двум, который может служить образцом решения более сложных задач.

На рисунке 1 вектор признаков $u = [u_1, u_2]$, описывающих исследуемую ситуацию состоит из двух признаков u_1 и u_2 отложенных по соответствующим координатным осям. Эксперту на основе своего опыта и знаний следует классифицировать произвольную ситуацию u , отнеся ее к классу А или к классу В. Поскольку классы линейно отделены, т.е. лежат в двух различных полупространствах, то их следует разделить прямой линией, называемой решающей границей (decision boundary).




Рис. 1. Графическая иллюстрация слабоформализуемых знаний эксперта

На рисунке 1 показано, что эксперт в своей повседневной практике чаще всего встречается с ситуациями, принадлежащими к областям A_1 и B_1 , находящимся в окрестностях точек $a_0 \in A_1$ и $b_0 \in B_1$ пространства признаков, описывающих наиболее типичных представителей каждого класса.

Евклидово расстояние

$$R(a_0, b_0) = \sqrt{\sum_{i=1}^n (u_{ia} - u_{ib})^2}, \quad (3)$$

где $n = 2$ (число координат равняется двум), между точками a_0 и b_0 , описывающими наиболее типичных представителей каждого класса, много больше расстояния от точки a_0 до границы области A_1 (B_1 аналогично).

Для областей A_1 и B_1 эксперты могут вербально объяснить правила классификации, которыми они пользуются в своей работе. Ситуации, принадлежащие к областям A_2 и B_2 (и не принадлежащие к A_1 и B_1) встречаются реже, эксперту вербально сформулировать правила классификации для этих ситуаций намного труднее, но возможно.

Далее, между областями A_2 и B_2 , находится область слабо формализуемых знаний эксперта. Здесь должна проходить линия решающей границы, но поскольку в этой области находятся редко встречающиеся на практике случаи возникновения ЧС, а эксперт при их классификации использует свои слабо формализуемые знания, то очень сложно определить, где следует провести эту линию (т.е. найти уравнение, задающее решающую границу).

В работе (Luger, 2008: 203–235) была выдвинута гипотеза и проведена серия экспериментов, подтвердивших, что эксперт при классификации интуитивно не использует правила разделения классов (т.е. уравнения решающих границ), но при этом способен верно отнести конкретные ситуации из области слабо формализуемых знаний к их классам.

Также установлено, что эксперты практически всегда способны корректно описать признаки (в том числе и с указанием их точных числовых значений) «наиболее типичных представителей» каждого исследуемого класса ситуаций (или объектов). Т.е. всегда можно найти и описать ситуации a_0 и b_0 , принадлежащие областям A_1 и B_1 :

$$\square a_0, a_0 \in A_1 \text{ и } \square b_0, b_0 \in B_1 \quad (4)$$

Определение этих особенностей работы эксперта при решении задач классификации, открывает возможности интеллектуализации разрабатываемой СППУР при возникновении ЧС на железнодорожном транспорте и извлечения знаний эксперта, относящихся к области слабоформализуемых знаний.

Технологии, относящиеся к интеллектуализации систем, включают в себя многие идеи разных дисциплин: математики, философии, психологии, биологии, теории управления и т.д. К началу 21-го века наука позволила разработчикам иметь у себя в арсенале несколько технологий интеллектуализации (продукционные правила, нейронные сети, генетические алгоритмы, нечеткая логика и т.д.), а также использовать их различные сочетания (т.н. «гибридные технологии») (Winston, 2020: 135–234).

Подход к созданию интеллектуальных экспертных и советующих систем, уже ставший «классическим» (Winston, 2020: 135–234; McCarthy, 2006: 12–14), предполагает использование баз знаний, содержащих совокупность фактов и правил логического вывода, моделирующих поведение эксперта с использованием процедур логического вывода и

принятия решений (производственные системы).

Эффективность производственных, нечетко-логических систем и их модификаций во многом определяется объемом и качеством содержащихся в них формализованных экспертных знаний. Для этого специалисты, которых называют инженерами по знаниям, при построении баз знаний, должны представить в формализованной форме логические рассуждения и заключения экспертов о предметной области, которые ложатся в основу базы знаний.

Как указывалось в предыдущем разделе, практически невозможно сформулировать адекватные правила-продукции для областей слабоформализуемых знаний. Построение и тестирование достоверных производственных моделей в этих областях вызывает серьезные трудности.

Согласно подходу к решению этой проблемы, используемому рядом авторов (Winston, 2020: 135–234), предлагается выделить те области пространства признаков, для которых отсутствуют достаточные данные, и если эти области имеют значительный размер, то просто исключить их из процесса моделирования, указав пользователю, что в этих областях модель неработоспособна.

Такой подход используется, но он не подходит для выбранной в исследовании предметной области, поскольку, как уже отмечалось, именно в таких, редко встречающихся случаях возникновения ЧС, ЛПР, не обладающее достаточным опытом, в наибольшей степени нуждается в интеллектуальной поддержке принятия своих решений.

В других подходах, являющихся наиболее перспективными с точки зрения их использования в разрабатываемой СППУР, используют методы, основанные на различных алгоритмах машинного обучения, среди которых в первую очередь следует выделить искусственные нейронные сети, позволяющие создавать работоспособные системы для слабоформализуемых областей знаний. Как отмечается в (Winston, 2020: 135–234), ИНС подходят для решения класса задач, где используются не столько формализованные правила, как в традиционных экспертных системах, сколько опыт самого эксперта.

Известно, что корректно обученные ИНС эффективно справляются с решением разнообразных практически востребованных задач классификации. На основе технологии ИНС и ее различных вариаций уже создано или находится в стадии разработки множество систем, применяемых для поддержки принятия решений в различных областях народного хозяйства, включая и железнодорожный транспорт.

ИНС представляют собой аппаратные и/или программные системы, построенные по принципу организации и функционирования сетей нервных клеток живых организмов. ИНС возникли в середине 20-го века, как попытка смоделировать процессы, протекающие в мозге человека.

ИНС является системой взаимодействующих между собой простых процессоров (искусственных нейронов), соединенных в достаточно большую сеть, имеющую несколько слоев. Каждый нейрон ИНС обрабатывает сигналы, которые он периодически получает, и сигналы, которые он посылает другим нейронам, если сумма сигналов соответствует заданному порогу (функции активации). Будучи соединенными в сеть, такие нейроны вместе способны решать сложные задачи, в частности, задачи классификации.

Процесс определения корректных весов межнейронных (синаптических) связей называется «обучением» ИНС. Возможность обучения – одно из главных преимуществ ИНС. Эффективность их работы зависит от правильной организации процесса обучения, что является важной и творческой задачей.

К одним из наиболее популярных способов машинного обучения ИНС решению задач классификации относится обучение «с учителем» (*supervised learning*), в ходе которого ИНС обучается с помощью примеров «стимул-реакция» (наборов пар, состоящих из обучающих векторов $u(n)$ и эталонных сигналов $d(n)$).

Между обучающими векторами и эталонными сигналами («стимул-реакция»)

существует некоторая зависимость, но она неизвестна. Известна только обучающая выборка – конечная совокупность из n пар «стимул-реакция». На основе этих данных требуется так настроить синаптические веса ИНС $w(n)$, чтобы по завершении процесса обучения ИНС могла корректно классифицировать поступающие на ее вход сигналы, включая и те, что отсутствовали в обучающей последовательности.

В отличие от производственных систем, где используется дедуктивное (лат. *deductio* – выводение) решение задач на основе ограниченного числа заранее определенных правил-продукций, обучение ИНС на основе некоторого множества предъявленных примеров (пар «стимул-реакция») является индуктивным обучением (лат. *inductio* – наведение), а формируемое ИНС предположение о виде неизвестных уравнений решающих границ – гипотезой.

Рассмотрим способ обучения ИНС «с учителем» в случае линейно сепарабельных классов на примере модели ИНС, называемой перцептрон. На рис. 2.2 представлена структура перцептрона, построенная в соответствии с описанием его создателя Ф. Розенблатта, приведенным в книге.

Задача перцептрона заключается в классификации вектора входных сигналов ИНС $u(n) = [u_1(n), \dots, u_N(n)]$ в смысле отнесения его к одному из двух классов (рассматриваемый случай, когда число классов $S = 2$), обозначаемых символами A и B .

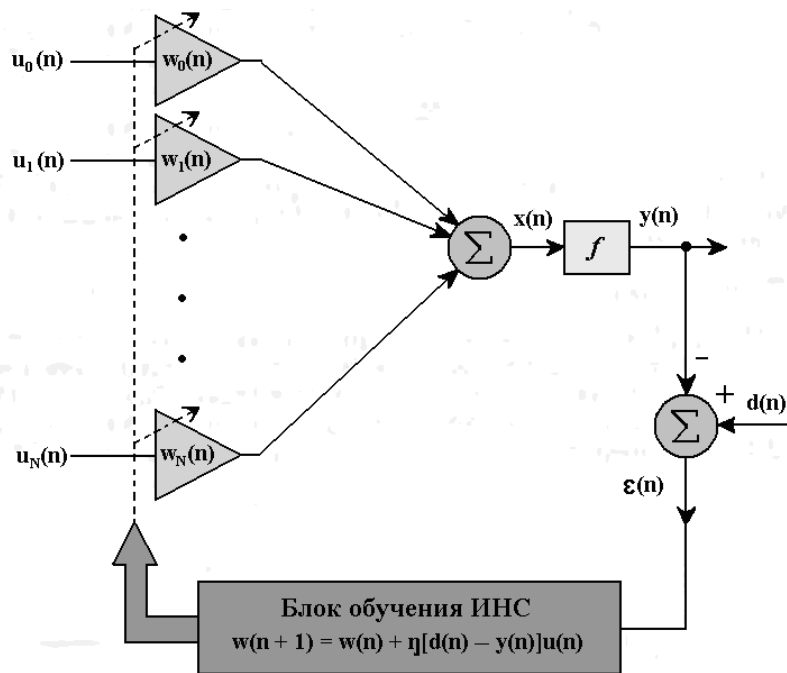


Рис. 2. Структура ИНС типа перцептрон

Т.к. в перцептроне в качестве функции активации f используется функция:

$$y = f\left(\sum_{i=0}^N w_i u_i\right), \quad (5)$$

в которой

$$f(x) = \begin{cases} 1, & \text{при } x \geq 0; \\ -1, & \text{при } x < 0, \end{cases} \quad (6)$$

где w_0, \dots, w_N – синаптические веса ИНС,

y – выходной сигнал ИНС, то перцептрон относит вектор $u(n)$ к классу A , если выходной сигнал y принимает значения 1 и, к классу B , если выходной сигнал y принимает

значение -1 .

Персептрон разделяет N -мерное пространство входных векторов $u(n)$ на два полупространства, разделяемые $(N-1)$ -мерной гиперплоскостью (решающей границей), задаваемой уравнением сигнала x на выходе линейной части персептрона:

$$\sum_{i=0}^N w_i u_i = 0, \quad (7)$$

где $w_0 u_0 = -v$ пороговое значение.

Решающая граница (7) при $N = 2$ превращается в прямую линию, задаваемую уравнением:

$$w_1 u_1 + w_2 u_2 - v = 0. \quad (8)$$

Любая точка $u(n) = [u_1, u_2]$, лежащая над этой прямой, показанной на рисунке 3, относится к классу A , тогда как точка $u(n) = [u_1, u_2]$, лежащая под этой прямой, будет относиться к классу B .




Рис. 3. Двумерное пространство входных векторов ИНС и разделяющая классы решающая граница

Блок обучения персептрона корректирует веса синаптических связей $w(n)$ по мере обучения в соответствии со следующей формулой:

$w(n+1) = w(n) + \eta[d(n) - y(n)]u(n)$. (9) Разность $d(n) - y(n)$ в формуле (9) является погрешностью $\epsilon(n)$ между эталонным (заданным) сигналом $d(n)$ и фактическим выходным сигналом $y(n)$, а параметр η при $0 < \eta < 1$ – это шаг коррекции синаптических весов. Доказано [75, 76], что алгоритм (9) с итерации *посходится*, т.е. $w(n_0) = w(n_0 + 1) = w(n_0 + 2) = \dots$ (10)

Согласно теореме сходимости алгоритма обучения персептрона с фиксированным приращением, это свидетельствует об окончании обучения.

Веса $w_i, i = 0, 1, \dots, N$ в уравнении гиперплоскости (7) изначально неизвестны. В процессе обучения на вход персептрона последовательно подаются обучающие векторы (сигналы) $u(n), n = 1, 2, \dots$, где $u(n) = [u_1(n), \dots, u_N(n)]$. Задача обучения персептрона, по сути, и состоит в поиске неизвестных значений синаптических весов w_i . Их нахождение позволяет построить гипотезу уравнения решающей границы. По завершении процесса обучения персептрон должен корректно классифицировать поступающие на его вход сигналы, в том числе и те, которые отсутствовали в обучающей последовательности $u(n), n = 1, 2, \dots, K$.

Классы, не соответствующие условию линейной сепарабельности, могут быть разделены ИНС типа перцептрон в случае увеличения числа ее слоев. Обучение других моделей ИНС «с учителем», в целом, происходит аналогично описанному выше. Под ИНС в дальнейшем будем обозначать искусственную нейронную сеть, подходящую для решения задач классификации и поддающуюся обучению путем коррекции вектора синаптических весов.

Очевидно, что точность имитации деятельности эксперта при помощи ИНС зависит от полноты и достоверности используемой обучающей выборки, что не всегда удается обеспечить на практике, особенно для описанных ранее слабо формализуемых предметных областей. Отсутствие достаточного ряда наблюдений исследуемых ситуаций не позволяет сформировать необходимого числа обучающих векторов для корректного обучения ИНС «с учителем».

Существует и такой способ обучения ИНС, при котором она устанавливается на рабочем месте опытного ЛПР и имеет возможность следить за фактически предпринимаемыми им действиями при возникновении тех или иных ситуаций, в результате чего обучается действовать в таких ситуациях подобно этому ЛПР. Однако, как уже неоднократно отмечалось, многие ЧС могут происходить достаточно редко, а поэтому на обучение ИНС таким образом может потребоваться непозволительно много времени (месяцы, годы).

Для преодоления указанных недостатков требуется разработка метода обучения ИНС, позволяющего производить обучение ИНС на основе знаний эксперта, в том числе и в слабо формализуемых предметных областях, за приемлемое время. Метод должен позволить обучить ИНС так, чтобы она содержала в себе знания конкретного эксперта, участвующего в ее обучении, и имитировала элементы его интеллектуальной деятельности при возникновении ЧС.

Такая постановка задачи согласуется с известным тестом, предложенным А.Тьюрингом, согласно которому компьютерная система считается интеллектуальной, если она может действовать подобно человеку. Академик В.М. Глушков сформулировал это таким образом, что следует искать «практически функционирующие алгоритмы, которые работали бы так же или лучше, чем специалист этой области».

Авторский метод обучения ИНС решению задач классификации на основе знаний эксперта, позволяющий преодолеть указанные трудности, будет подробно описан в следующем разделе диссертации.

Заключение

Целью настоящего исследования являлась интеллектуализация поддержки принятия управленческих решений при возникновении чрезвычайных ситуаций (ЧС) на железнодорожном транспорте. Для достижения поставленной цели были определены объект и предмет исследования: объектом выступали процессы принятия управленческих решений при ЧС, предметом — методы и алгоритмы интеллектуализации деятельности ЛПР с использованием экспертных знаний и технологий искусственных нейронных сетей (ИНС).

Методы исследования включали системный анализ, классификацию ЧС, машинное обучение, математическое моделирование и экспертные методы. В качестве материала исследования использовались сведения о более чем 200 случаях ЧС на железнодорожном транспорте за период 2013–2024 годов, архивные материалы предприятий железнодорожного транспорта, публикации научных источников, материалы международных конференций и описание технологий интеллектуализации.

В ходе исследования была подтверждена гипотеза о том, что использование ИНС, обученных на основе знаний экспертов, позволяет воспроизводить действия ЛПР при ЧС с достаточной точностью и оперативностью, включая редкие и слабоформализуемые ситуации. Проведен анализ интеллектуальных задач, решаемых ЛПР, в том числе задачи

оценки масштаба ЧС и классификации состояния атмосферы при авариях с АХОВ. Выявлены области, в которых экспертные знания трудно формализуются, и предложен метод обучения ИНС с использованием опыта конкретного ЛПР для воспроизведения действий эксперта в этих областях.

Результаты исследования показали, что построение обучающих выборок на основе экспертного опыта позволяет ИНС корректно классифицировать различные типы ЧС, прогнозировать масштаб последствий и формировать рекомендуемые наборы действий для ЛПР. Обучение «с учителем» на базе экспертных данных обеспечивает индуктивное моделирование решений и воспроизводство действий эксперта, что особенно важно при слабоформализуемых ЧС, которые возникают редко и требуют оперативного реагирования.

Выводы исследования заключаются в следующем:

- Интеллектуализация поддержки принятия управленческих решений позволяет повысить оперативность и точность действий ЛПР при ЧС на железнодорожном транспорте.

- Использование искусственных нейронных сетей обеспечивает моделирование действий экспертов, включая слабоформализуемые и редкие случаи ЧС.

- Формализация экспертных знаний в виде обучающих выборок и их интеграция в ИНС повышает достоверность рекомендаций ЛПР и снижает риск необоснованных материальных и людских затрат при ликвидации ЧС.

- Разработанная методика обучения ИНС позволяет адаптировать систему к специфике конкретной железнодорожной станции, обеспечивая массовое тиражирование и внедрение системы поддержки принятия решений.

Перспективы внедрения результатов исследования включают:

- использование разработанных моделей ИНС в системах автоматизированного управления ЧС на железнодорожном транспорте;

- интеграцию ИНС с современными системами мониторинга состояния инфраструктуры и технологических процессов;

- создание обучающих программ для ЛПР с использованием симуляций и сценариев реальных ЧС;

- расширение применения предложенной методики на другие транспортные и критически важные отрасли, где действия ЛПР определяются редкими и слабоформализуемыми событиями.

Таким образом, исследование подтвердило истинность выдвинутого тезиса о возможности интеллектуализации поддержки принятия решений на основе экспертных знаний и машинного обучения. Полученные результаты способствуют изменению научного знания в области управления ЧС на железнодорожном транспорте, предлагая новый подход к обучению и поддержке ЛПР, обеспечивая повышение эффективности ликвидации последствий ЧС, минимизацию затрат и рисков, а также открывая перспективы дальнейших исследований в области интеллектуальных систем поддержки управленческих решений.

ЛИТЕРАТУРА

Асанов, 2002 — Асанов А.А. Методы извлечения и анализа экспертных знаний: автореф. дис. На соискание ученой степени кандидата техн. наук по спец-ти 05.13.10. — Москва: Институт системного анализа РАН. — 2002. — 129 с. [Russ.]

Васильев, 2000 — Васильев С.Н., Жерлов А.К., Федосов Е.А., Федунев Б.Е. Интеллектуальное управление динамическими системами — М.: Физико-математическая литература. — 2000. — 352 с. [Russ.]

Кульба, 2013 — Кульба В.В., Шелков А.Б., Чернов И.В. Анализ эффективности использования сценарного подхода в процессах управления ликвидацией последствий ЧС на объектах инфраструктуры железнодорожного транспорта // Интеллектуальные системы управления на железнодорожном транспорте (ИСУЖТ-2013): Вторая научно-техническая конференция (21–22 октября 2013 г., Москва, Россия). ОАО «НИИАС». — 2013. — С. 180–183. [Russ.]

Цуриков, 2013 — Цуриков А.Н., Гуда А.Н., Вережкина О.И., Домницкий Н.К. Принципы построения интеллектуальной советующей системы управления и оповещения при ликвидации последствий чрезвычайных ситуаций на железнодорожном транспорте // Проблемы анализа риска. — 2013. — Т. 10. — № 5. — С. 56–65. [Russ.]

Смирнов, 2024 — Смирнов А.В., Пономарёв А.В., Шилов Н.Г. и др. Концепция построения коллаборативных систем поддержки принятия решений: подход и архитектура платформы. // Информатика и автоматизация. — 2024. — 23(4). — P. 1100–1138. [Eng.]

Callan, 2013 — Callan R. The Essence of Neural Networks — Harlow, England: Prentice Hall Europe. — 1999. — 248 p. [Eng.]

Tsurikov, 2013 — Tsurikov A.N. Application of artificial neural network for identification of stability of bottom layer of atmosphere // Applied and Fundamental Studies: Proceedings of the 2nd International Academic Conference. — March 8-10, 2013. — Publishing House «Science and Innovation Center». — St. Louis, Missouri, USA. — 2013. — P. 226–231. [Eng.]

Winston, 2020 — Winston P. H. Artificial Intelligence: A Modern Approach. 4th ed. — Pearson, 2020. — 1152 p. [Eng.]

Luger, 2008 — Luger G. F. Artificial Intelligence: Structures and Strategies for Complex Problem Solving. 6th ed. — Pearson. — 2008. — 720 p. [Eng.]

McCarthy, 2006 — McCarthy J., Minsky M. L., Rochester N., Shannon C. E. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence // AI Magazine. — 2006. — Vol. 27. — No. 4. — P. 12–14. [Eng.]

REFERENCES

Asanov, 2002 — Asanov, A.A. (2002). Metody izvlecheniya i analiza ekspertnykh znaniy [Methods of extraction and analysis of expert knowledge]: Avtoref. dis. na soiskanie uchenoi stepeni kandidata tekhn. nauk po spetsial'nosti 05.13.10. — Moskva: Institut sistemnogo analiza RAN. — 2002. — 129 p. [in Russ.]

Callan, 1999 — Callan, R. (1999). The Essence of Neural Networks. — Harlow, England: Prentice Hall Europe. — 1999. — 248 p. [in Eng.]

Kul'ba, 2013 — Kul'ba, V.V., Shelkov, A.B., Chernov, I.V. (2013). Analiz effektivnosti ispol'zovaniya stsennarnogo podkhoda v protsessakh upravleniya likvidatsiei posledstviy ChS na ob'ektakh infrastruktury zheleznodorozhnogo transporta [Analysis of the effectiveness of the scenario-based approach in managing emergency response at railway infrastructure facilities]. — Moskva: OAO «NIAS». — 2013. — Pp. 180–183. [in Russ.]

Luger, 2008 — Luger, G.F. (2008). Artificial Intelligence: Structures and Strategies for Complex Problem Solving. 6th ed. — Pearson. — 2008. — 720 p. [in Eng.]

McCarthy, 2006 — McCarthy, J., Minsky, M.L., Rochester, N., Shannon, C.E. (2006). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. — AI Magazine. — 2006. — Vol. 27, No. 4. — Pp. 12–14. [in Eng.]

Tsurikov, 2013 — Tsurikov, A.N., Guda, A.N., Verevkina, O.I., Domnitskii, N.K. (2013). Printsipy postroeniya intellektual'noi sovetuyushchei sistemy upravleniya i opovescheniya pri likvidatsii posledstviy chrezvychainykh situatsii na zheleznodorozhnom transporte [Principles of building an intelligent advisory and alert system for emergency response on railway transport]. — Problemy analiza riska. — 2013. — Vol. 10. — No. 5. — Pp. 56–65. [in Russ.]

Tsurikov, 2013 — Tsurikov, A.N. (2013). Application of artificial neural network for identification of stability of bottom layer of atmosphere. — St. Louis, Missouri, USA: Publishing House «Science and Innovation Center». — 2013. — Pp. 226–231. [in Eng.]

Vasil'ev, 2000 — Vasil'ev, S.N., Zherlov, A.K., Fedosov, E.A., Fedunov, B.E. (2000). Intellektnoe upravlenie dinamicheskimi sistemami [Intelligent control of dynamic systems]. — Moskva: Fiziko-matematicheskaya literatura. — 2000. — 352 p. [in Russ.]

Smirnov, 2024 — Smirnov, A.V., Ponomaryov, A.V., Shilov, N.G. et al. (2024). Kontseptsiya postroeniya kollaborativnykh sistem podderzhki prinyatiya reshenii: podkhod i arkhitektura platformy [Concept for building collaborative decision support systems: approach and platform architecture]. — Informatika i avtomatizatsiya. — 2024. — 23(4). — Pp. 1100–1138. [in Eng.]

Winston, 2020 — Winston, P.H. (2020). Artificial Intelligence: A Modern Approach. 4th ed. — Pearson. — 2020. — 1152 p. [in Eng.]