

Применение искусственного интеллекта для прогнозирования правонарушений и преступлений на транспорте: теория и методология

Кирилл Витальевич Злоказов¹, доктор психологических наук, доцент
Грант Рубенович Сархошян²

¹ Санкт-Петербургский университет МВД России

Санкт-Петербург (198206, ул. Летчика Пилутова, д. 1), Российская Федерация

² Управление на транспорте МВД России по Северо-Западному федеральному округу

Санкт-Петербург (191124, ул. Ярославская, 4), Российская Федерация

¹ kzlokazov@mvd.ru, ² nio.spbu@yandex.ru

¹ <https://orcid.org/0000-0002-0664-8444>, ² <https://orcid.org/0009-0007-3870-6382>

Аннотация:

Введение. Актуальность исследования обусловлена вызовами и угрозами объектам транспорта и транспортной инфраструктуры, а также возможностями цифровой трансформации оперативно-служебной деятельности органов внутренних дел Российской Федерации. Рост несанкционированных вмешательств и общественная опасность посягательств требуют оптимизации деятельности полиции на транспорте, которая в свою очередь может быть эффективно осуществлена с опорой на методы искусственного интеллекта – нейросетевого прогнозирования. Цель – систематизация теории и методологии применения нейросетевых технологий для прогнозирования правонарушений и преступлений на объектах транспортной инфраструктуры, осуществляемая для повышения эффективности деятельности полиции на транспорте.

Методы исследования: общенаучные методы анализа, систематизации и конкретизации, использованные в отношении сведений о применении искусственного интеллекта и нейросетевых систем прогнозирования правонарушений и преступлений на транспорте.

Результаты. Проанализированы отечественные и зарубежные технологии искусственного интеллекта, применяемые при прогнозировании правонарушений и преступлений, систематизированы нейросетевые методы прогнозирования, пригодные для построения моделей правонарушений и преступлений; конкретизирован алгоритм прогноза правонарушений и преступлений на транспорте и объектах транспортной инфраструктуры посредством нейросетевой технологии применения искусственного интеллекта. Показано, что многослойный перцептрон (MLP), рекуррентная нейронная сеть (RNN), временная сверточная сеть (TCN), графовая нейронная сеть (GNN) могут применяться для оперативного (в режиме реального времени), а также стратегического (криминологического) прогноза правонарушений и преступлений на транспорте. Приводятся примеры нейросетевых моделей, используемых для решения задач прогнозирования правонарушений и преступлений на транспорте. С учетом выполненного анализа формулируется алгоритм разработки нейросетевой модели прогноза правонарушений и преступлений. Описываются четыре этапа его осуществления, позволяющие перейти к практическому воплощению (разработке) модели прогноза.

Ключевые слова:

интеллектуальное прогнозирование преступлений, искусственная нейронная сеть, нейросетевой прогноз преступлений, нейросетевой анализ правонарушений, интеллектуальное предсказание преступлений, криминологический прогноз, информационные технологии прогнозирования правонарушений

Для цитирования:

Злоказов К. В., Сархошян Г. Р. Применение искусственного интеллекта для прогнозирования правонарушений и преступлений на транспорте: теория и методология // Вестник Санкт-Петербургского университета МВД России. 2026. № 1 (109). С. 128–143.

Статья поступила в редакцию 22.05.2025; одобрена после рецензирования 07.10.2025; принята к публикации 25.12.2025.

Original article

The application of artificial intelligence for predicting offences and crimes in transport: theory and methodology

Kirill V. Zlokazov¹, Doc. Sci. (Psy), Docent
Grant R. Sarkhoshyan²

¹ Saint Petersburg University of the MIA of Russia

1, Letchika Pilyutova str., Saint Petersburg, 198206, Russian Federation

² Transport Directorate of the Ministry of Internal Affairs of Russia for the Northwestern Federal District
4, Yaroslavskaia str., Saint Petersburg, 191124, Russian Federation

¹ kzlokazov@mvd.ru, ² nio.spbu@yandex.ru

¹ <https://orcid.org/0000-0002-0664-8444>, ² <https://orcid.org/0009-0007-3870-6382>

Abstract:

Introduction. The relevance of this study stems from the challenges and threats facing transport facilities and infrastructure, as well as the opportunities presented by the digital transformation of the operational activities of the internal affairs agencies of the Russian Federation. The rise in unauthorised interference and the public danger posed by such offences necessitate the optimisation of police operations in the transport sector, which, in turn, can be effectively achieved by relying on artificial intelligence methods – specifically, neural network forecasting.

Objective: to systematise the theory and methodology of applying neural network technologies for forecasting offences and crimes at transport infrastructure facilities, carried out to enhance the effectiveness of police operations in the transport sector.

Research methods: general scientific methods of analysis, systematization and specification, applied to data on the use of artificial intelligence and neural network systems for forecasting offences and crimes in transport.

Results. Domestic and foreign artificial intelligence technologies used in the prediction of offences and crimes have been analysed; neural network prediction methods suitable for constructing models of offences and crimes have been systematised; an algorithm for predicting offences and crimes in transport and at transport infrastructure facilities using neural network technology based on artificial intelligence has been specified. It has been demonstrated that a multi-layer perceptron (MLP), a recurrent neural network (RNN), temporal convolutional network (TCN) and graph neural network (GNN) can be applied for operational (in real-time) as well as strategic (criminological) prediction of offences and crimes in transport. Examples are provided of neural network models used to solve the problem of forecasting offences and crimes in transport. Based on the analysis carried out, an algorithm is formulated for developing a neural network model for forecasting offences and crimes. Four stages of its implementation are described, enabling the practical realization (development) of the forecasting model.

Keywords:

intelligent crime prediction, artificial neural network, neural network crime prediction, neural network analysis of offences, intelligent prediction of crimes, criminological forecasting, information technologies for offence prediction

For citation:

Zlokazov K. V., Sarkhoshyan G. R. The application of artificial intelligence for predicting offences and crimes in transport: theory and methodology // Vestnik of Saint Petersburg University of the MIA of Russia. 2026. № 1 (109). P. 128–143.

The article was submitted May 22, 2025;
approved after reviewing October 7, 2025;
accepted for publication December 25, 2025.

Введение

Актуальность исследования заключается в возможностях цифровой трансформации деятельности органов внутренних дел Российской Федерации в части противодействия преступности. Осуществление криминальных посягательств группой лиц и применение ими высокотехнологичных устройств, увеличение общественной опасности их деяний, становится настоящим вызовом, ответом на который является цифровая модернизация деятельности полиции. Как неоднократно подчеркивал президент Российской Федерации Владимир Владимирович Путин, будущее государственного управления и, в частности, правоохранительной системы неразрывно связано с внедрением цифровых платформ и искусственного интеллекта¹.

Необходимость поиска новых методов противодействия правонарушениям и преступлениям на объектах транспорта обусловлена ролью транспортной инфраструктуры в жизни страны. Высокая концентрация людей и материальных ценностей, гетерогенность и динамика транспортных потоков, открытость транспортной инфраструктуры создают благоприятную среду для

¹ Искусственный интеллект трансформирует в России всю систему госуправления // ComNews: [электронное издание]. URL: https://www.comnews.ru/content/23686_2/2024-12-13/2024-w50/1009/iskusstvennyy-intellekt-transformiruet-rossii-vsyu-sistemu-gosupravleniya (дата обращения: 01.09.2025).

совершения правонарушений – от краж грузов и личного имущества пассажиров, актов хулиганства до диверсий и террористических посягательств. В этих условиях назрела потребность перехода к проактивной, прогнозно-превентивной парадигме управления деятельностью органами внутренних дел на транспорте, основанной на обработке данных и передовых технологиях их анализа.

С учетом имеющегося зарубежного опыта применения нейросетевых технологий ясно, что интеграция информационных систем различных подразделений МВД и транспортной инфраструктуры может снизить риск криминализации. Объединение в аналитическом контуре данных о пассажиропотоке, расписании движения, записях с камер видеонаблюдения, данных о правонарушениях и оперативной обстановке позволит эффективно использовать силы и средства полиции на транспорте для предупреждения преступлений. Освоение нейросетевых методов прогнозирования открывает путь к созданию прогнозных моделей, способных не только предсказывать уровень преступности на транспорте на основе сведений об уровне преступности прошлых лет, но и оценивать риски преступлений в режиме реального времени.

Цель статьи состоит в систематизации теоретических основ и разработке алгоритма по применению нейросетевых технологий для прогнозирования правонарушений и преступлений на объектах транспортной инфраструктуры, осуществляемого в целях повышения эффективности деятельности подразделений полиции на транспорте.

Для достижения цели решаются следующие задачи: анализируются отечественные и зарубежные технологии искусственного интеллекта, применяемые при прогнозировании правонарушений и преступлений; описываются нейросетевые методы прогнозирования, пригодные для построения моделей правонарушений и преступлений; представлен алгоритм прогноза правонарушений и преступлений посредством нейросетевого метода.

Результатом является расширение представлений о возможностях применения нейросетевых технологий для противодействия правонарушениям и преступлениям на транспорте и объектах транспортной инфраструктуры, систематизированное знание о нейросетевых моделях и их параметрах, применимое для разработки конкретных нейросетевых решений, нацеленных на криминологический (долгосрочный) и оперативный прогноз состояния правонарушений и преступлений на транспорте.

Методы

Основу исследования составили общенаучные методы анализа, систематизации и конкретизации, использованные в отношении сведений о применении искусственного интеллекта и нейросетевых систем прогнозирования правонарушений и преступлений на транспорте.

Результаты

Теоретические основания применения технологий искусственного интеллекта для прогнозирования правонарушений и преступлений

Искусственный интеллект определяется как «комплекс технологических решений, позволяющий имитировать когнитивные функции человека (включая самообучение и поиск решений без заранее заданного алгоритма) и получать при выполнении конкретных задач результаты, сопоставимые как минимум с результатами интеллектуальной деятельности человека»². Под комплексом технологических решений понимается информационно-коммуникационная инфраструктура, программное обеспечение, включающее в т. ч. и машинное обучение, а также процессы и сервисы по обработке больших данных и поиску решений.

Анализ зарубежных и отечественных публикаций показывает, что технологии используются в нескольких основных направлениях:

– Противодействие правонарушениям и преступлениям, совершаемым посредством информационно-коммуникационных технологий, в т. ч. в интернете. Использование технологий основывается на выявлении антиобщественных и противозаконных действий в цифровой среде, их документировании в целях уголовного преследования и блокировании [1]. Наиболее эффективно данные технологии применяются в отношении преступлений против собственности

² О развитии искусственного интеллекта в Российской Федерации (вместе с Национальной стратегией развития искусственного интеллекта в России до 2030 года): Указ Президента Российской Федерации от 10 октября 2019 г. № 490 (ред. от 15.02.2024) // Собрание законодательства Российской Федерации (далее – СЗ РФ). 2019. № 41. Ст. 5700.

(мошенничество), жизни и здоровья (доведение до самоубийства), против свободы, чести и достоинства личности (клевета), половой неприкосновенности и половой свободы (развратные действия), общественной безопасности и общественного порядка (призывы к осуществлению террористической деятельности, публичное оправдание терроризма, возбуждение ненависти либо вражды, унижение человеческого достоинства и пр.).

– Предупреждение преступлений, совершаемых в общественных местах с помощью методов анализа поведения (предиктивная аналитика). Наибольшую эффективность продемонстрировал метод «компьютерного зрения», примененный к признакам правонарушающего поведения [2]. Благодаря компьютерной обработке информации с видеокамер повысились возможности установления личности разыскиваемых лиц, в т. ч. подозреваемых, обвиняемых, свидетелей и потерпевших [3], выявляемость действий водителей транспортных средств, нарушающих правила проезда перекрестков, превышающих разрешенную скорость движения [4]. Наблюдение за поведением лиц в общественных местах позволило заблаговременно выявлять лиц в состоянии опьянения, дезориентированных и неадекватно реагирующих, нарушающих правила поведения [5].

– Прогнозирование правонарушений и преступлений (криминологическое прогнозирование) [6]. Прогнозирование представляет собой совокупность методов (а) пространственного, пространственно-временного и сетевого анализа, применяемых для определения вероятности совершения преступления на определенных участках местности; (б) персонологического прогнозирования совершения преступлений определенными лицами и /или группами [4].

К наиболее распространенным видам пространственного прогнозирования относится топографическое картирование (геопрофайлинг) [7]. Оно осуществляется путем оценки криминологической ситуации в определенных районах и в целом населенных пунктах, участках транспортных магистралей и узлов. Результатом картирования выступает топологическая модель преступлений («очаг преступлений»), составляемая на основе сообщений о происшествиях [8]. При этом географическая оценка криминогенности опирается не только на оперативную информацию, но и на сведения, поступающие от населения. Они включают:

- во-первых, сигналы о совершающихся правонарушениях и преступлениях;
- во-вторых, обращения и жалобы потерпевших;
- в-третьих, криминогенно значимые социальные, культурные и экономические характеристики деятельности населения.

К ним относятся такие показатели, как вандализм, порча зданий и сооружений, наличие бесхозной и разрушенной городской инфраструктуры [9]. Традиционный способ криминологического геопрофайлинга предполагает работу сотрудников полиции с географическими информационными системами и информационными сводками о правонарушениях и преступлениях. Несмотря на эффективность, данный способ трудоемок и отнимает много времени [10].

Неспособность сотрудника-оператора оценивать большие объемы информации за короткое время существенно затрудняет отслеживание преступной деятельности, обладающей динамичным, меняющимся характером. Кроме того, ручной ввод может привести к неточной идентификации криминогенных областей и ошибкам прогнозирования.

Статистические методы активно используются для предсказания преступности в масштабах страны, региона, города или района. Эти методы предполагают расчет плотности и распределения происшествий, связанных с преступлениями, в пределах определенного времени³ [11; 12]. Предметом анализа является поиск статистически значимых событий, в то время как автокорреляция оценивает степень связи событий, связанных с преступлениями. Хотя статистические методы более продуктивны в обработке информации, чем ручной анализ, они ограничены тем, что опираются на заранее определенные статистические модели и пороговые значения, которые могут неточно отражать состояние преступности [13].

Персонологическое картирование осуществляется путем расчета показателей вреда, позволяющих выявить потенциально опасных преступников. Распространенным методом является взвешенная совокупность статических факторов, таких как тяжесть преступления и вид наказания [14]. Для изучения криминогенных групп и сообществ на основе теории графов разработана методология изучения их взаимодействия. Анализ связей используется для разработки ассоциативных матриц и диаграмм взаимодействия криминогенных лиц, а сетевой анализ используется для выявления состава преступных групп, определения структуры лидерства, выявления степени готовности к совершению преступления, изобличению участников на этапе уголовного преследования [8].

³ Федорова О. Б., Хейло Л. Г. Статистические методы анализа, оценки и прогнозирования оперативной обстановки : учебно-методическое пособие. Москва : ОАД МВД России, 2018. 85 с.

Завершая обзор технологий, применяемых для прогнозирования правонарушений и преступлений, сформулируем ряд выводов. Успешное применение данных методов актуализирует развитие технологий, совершенствующих и ускоряющих обработку массивов гетерогенных данных. Положительных результатов сегодня удастся достичь благодаря применению аппаратно-программного комплекса «Безопасный город», автоматизированной информационной системы «Карта криминогенности», системы биометрического распознавания лиц «Сфера» и аналогичных интеллектуальных средств прогнозирования правонарушений и преступлений [15].

Недостатки использования классической методологии прогнозирования правонарушений и преступлений обусловлены естественными ограничениями способности операторов – сотрудников полиции воспринимать и интерпретировать объемы данных, а также тем, что классическим инструментам математико-статистического прогнозирования не хватает аналитической глубины, необходимой для выявления тонких закономерностей и тенденций. Они не могут эффективно интегрировать многочисленные источники данных или учитывать влияние различных социально-экономических и экологических факторов на преступность. Кроме того, эти методы обычно обеспечивают статичное представление данных о преступлениях, не отражая динамических и временных аспектов преступной деятельности. Существенных результатов удастся достичь благодаря применению методологии нейросетевого подхода к прогнозированию правонарушений и преступлений.

Нейросетевые методы прогнозирования, пригодные для построения моделей правонарушений и преступлений

Методология разработки прогноза правонарушений и преступлений в настоящее время представляет собой широкую группу методов, основывающихся на интуитивных (иррациональных), субъективных (индивидуальных) и формализованных (статистических) основаниях (рисунок 1). Наибольшую разработку и применение получили формализованные методы [16].

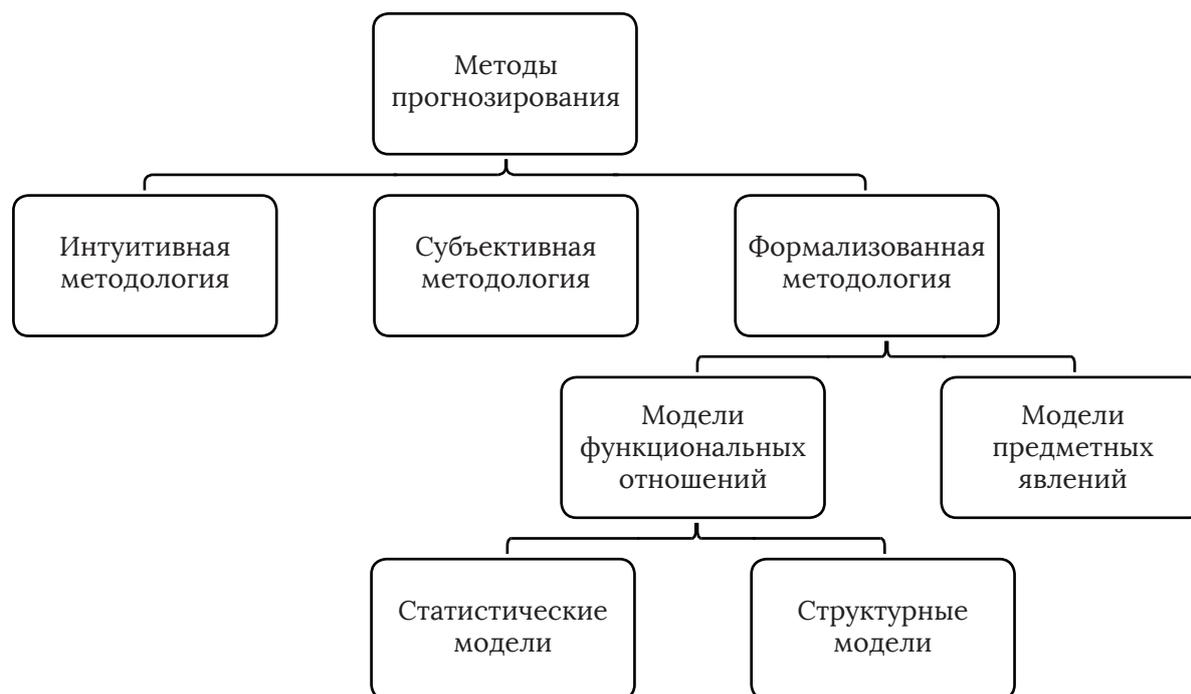


Рисунок 1 – Классификация методологии и методов прогнозирования
Figure 1. Classification of forecasting methodologies and methods

Формализованные методы, применяемые для разработки статистических и структурных моделей предсказания правонарушений и преступлений, основываются на процедурах изучения зависимостей, образующих само явление [17]. Статистические виды моделей строятся на анализе ассоциаций, корреляций и регрессий, тогда как структурные модели представляют собой более сложные процедуры, предполагающие выявление многомерных зависимостей, и предполагают классификацию, кластеризацию и детерминацию между различными причинами и условиями преступлений [18].

Методология нейросетевых методов дополняет статистические и структурные модели, развивая и расширяя их возможности. Основу нейросетевых методов составляет теория нейронных сетей, представляющая собой алгоритмическое моделирование нейрофизиологических процессов средствами математической статистики.

Фактически нейросетевой метод воспроизводит деятельность нервных клеток по получению, обработке и передаче нервных импульсов. Имитация нейронной сети с помощью аппаратно-программных средств обеспечивает обработку, анализ и интерпретацию больших объемов данных, позволяя в режиме реального времени оценивать риски криминальных посягательств и противодействовать им. В настоящее время прогнозирование правонарушений и преступлений с использованием нейросетевых методов осуществляется в нескольких направлениях:

– моделирование и прогнозирование преступности в реальном времени с использованием сетей интернета вещей и облачных вычислений;

– когнитивное моделирование с использованием искусственного интеллекта для анализа структуры правонарушений и преступлений прошлых лет на основе статистики их совершения;

– моделирование антиобщественного поведения и его нейросетевая симуляция при прогнозировании преступности в общественных местах в условиях высокой плотности населения;

– обеспечение раннего предупреждения правонарушений и преступлений на основе сетевых методов оценки взаимодействия криминогенных лиц путем анализа их коммуникации;

– прогнозирующее наблюдение с помощью беспилотных летательных аппаратов с использованием встроенного искусственного интеллекта для мониторинга правонарушений и преступлений;

– разработка визуальных моделей поведения правонарушителей и преступников для моделирования сценариев городских преступлений в режиме реального времени.

Наряду с указанными направлениями зарубежные исследователи ведут разработку нейросетевых методов обработки разнородных данных в реальном времени, что позволит ускорить реагирование на ситуацию. В числе перспективных направлений указаны:

а) разработка нейросимволического интеллекта, позволяющего обрабатывать сообщения в информационно-коммуникационных сетях и выявлять призывы к совершению преступлений на основе оценки их криминогенного контекста и эмоционального потенциала высказываний;

б) создание интеллектуальных средств оптимизации патрулирования нарядами полиции городских улиц на основе самообучающихся нейронных сетей;

в) интеграция киберфизических систем и систем компьютерного зрения для предупреждения преступности в интеллектуальных городских инфраструктурах.

Таким образом, нейросетевые технологии прогнозирования правонарушений и преступлений опираются на использование математико-статистического анализа и ориентированы на расширение методологии нейросетей при моделировании вероятных и потенциально преступных действий. Нейросетевые методы отличаются от «классических» универсальностью применения, гибкостью и точностью прогнозирования, способностью обобщать значительные объемы информации об обстоятельствах и условиях преступлений без дополнительной корректировки или переобучения, возможность применения для производства прогнозов сотрудниками, не имеющими специальной подготовки в сфере математической статистики.

Архитектуру нейросетевого метода образуют две процедуры работы с данными – метод машинного обучения (далее – machine learning, ML) и обработки естественного языка (далее – natural language processing, NLP). В настоящее время разработанные на их основе алгоритмы составляют более 90 % процедур обработки данных о преступлениях, данных видеонаблюдений в режиме реального времени, анализа сообщений граждан о происшествиях [19; 20]. К основным нейросетевым алгоритмам относятся следующие.

1. Многослойный перцептрон (MLP) – класс искусственных нейронных сетей прямого пространства, состоит из нескольких слоев, имитирующих нейроны, каждый из которых выполняет свою функцию (рисунок 2). Типовыми слоями многослойного перцептрона являются:

А. Входной слой. Принимает исходные данные (признаки) для обработки. Число нейронов в этом слое соответствует размерности входных данных.

Б. Один или несколько скрытых слоев. Эти слои находятся между входным и выходным слоями. В них происходит основная обработка данных, где нейроны используют нелинейные функции активации

В. Выходной слой. Выдает конечный результат работы сети. Число нейронов в этом слое зависит от решаемой задачи. Например, для классификации может быть несколько нейронов, каждый из которых соответствует определенному классу.

Нейросети на основе MLP применяются к структурированным массивам сведений о преступлениях. Они отличаются простотой, быстрой обучаемостью, относительно легкой интерпретацией результата. Недостатком является неспособность учитывать временную последовательность преступлений и их локализацию в различных районах города, неспособность компенсировать недостатки (ошибки) данных.

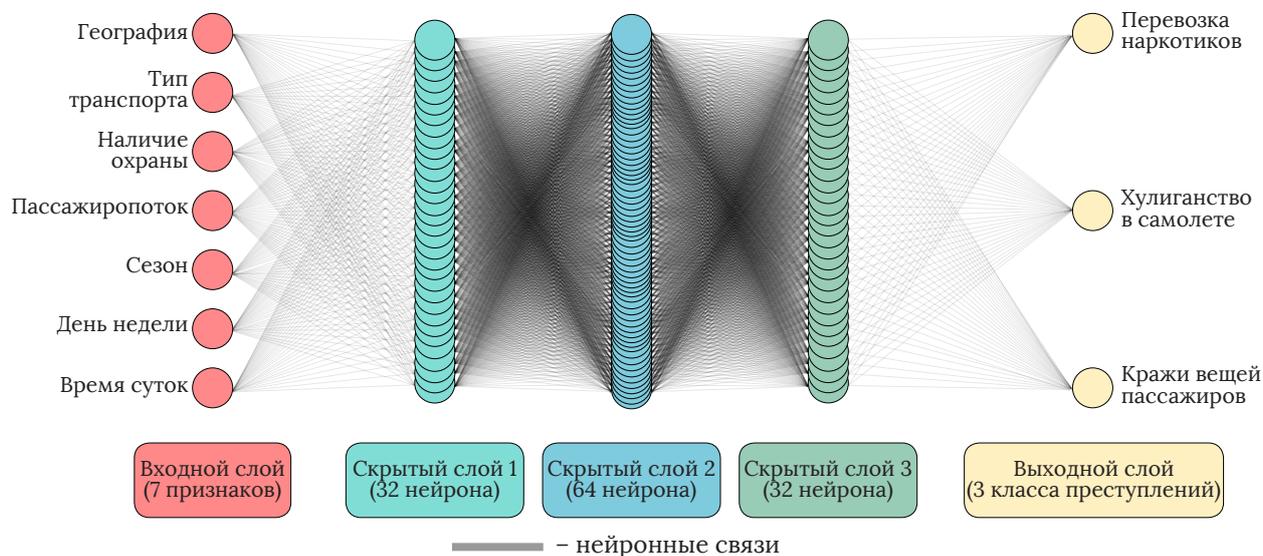


Рисунок 2. Пример архитектуры нейросети многослойного перцептрона, ориентированной на прогнозирование преступлений на транспорте⁴
Figure 2. Example of a multi-layer perceptron neural network architecture designed for forecasting transport-related crimes

Нейросети на основе MLP применяются к структурированным массивам сведений о преступлениях. Они отличаются простотой, быстрой обучаемостью, относительно легкой интерпретацией результата. Недостатком является неспособность учитывать временную последовательность преступлений и их локализацию в различных районах города, неспособность компенсировать недостатки (ошибки) данных.

Нейросети на основе MLP применяются к структурированным массивам сведений о преступлениях. Они отличаются простотой, быстрой обучаемостью, относительно легкой интерпретацией результата. Недостатком является неспособность учитывать временную последовательность преступлений и их локализацию в различных районах города, неспособность компенсировать недостатки (ошибки) данных.

Построение нейросети позволяет прогнозировать три вида преступлений с учетом места их совершения – перевозка наркотиков, хулиганство в самолете, кража вещей пассажиров на вокзале – и детали транспорта, пассажиропоток, сезон, день недели и время суток). Нейросеть анализирует параметры каждого вида преступления на основе сведений о нем. Результатом становится оценка риска преступлений, дифференцированная по видам транспорта и вокзалам.

2. Рекуррентные нейронные сети (RNN) представляют собой разновидность нейронных сетей, предназначенных для обработки последовательных данных о преступлениях. В отличие от многослойных перцептронов (MLP), у RNN есть способность сохранять информацию и использовать ее для обработки новой информации.

Более совершенными разновидностями рекуррентной сети выступают нейросеть с длительной краткосрочной памятью (Long Short-Term Memory, LSTM), а также нейросеть с управляемым рекуррентным блоком (Gated Recurrent Unit, GRU). Данные модели нейросетей эффективны при работе с длинными и сложными последовательностями данных, поскольку способны управлять сохраняемой информацией. Они могут быть использованы для выявления основных обстоятельств совершения преступлений с учетом фактора времени (прогноз количества правонарушений в следующем периоде, оценка риска совершения преступлений по районам города и времени суток).

⁴ Входной слой нейросети получает сведения об обстоятельствах и условиях ранее совершенных преступлений, в скрытых слоях данная информация обрабатывается и дифференцируется по выбранным видам преступлений.

При применении для оценки хулиганства RNN нейросеть обобщает сведения о случаях хулиганства и на основе оценки параметров запоминает признаки и обнаруживает последовательности, позволяющие прогнозировать риск хулиганства, адаптируя его оценку к видам рейсов (маршрутов), динамике пассажиропотока, социально-демографическим характеристикам пассажиров. Так, RNN нейросеть осуществляет мониторинг пассажиропотока в реальном времени (рисунок 3). На основании данных видеонаблюдения обнаруживаются модели поведения, свидетельствующие о состоянии алкогольного опьянения, конфликтности пассажиров в конкретный момент времени ожидания рейса. Запоминая эти сведения посредством блоков LSTM, нейросеть «распознает» пассажиров, ранее уже демонстрировавших признаки опьянения или конфликтности. С учетом контекстных данных (информации, уточняющей характеристики и состоянии данных пассажиров), нейросеть прогнозирует риск акта хулиганства с их стороны в период полета.

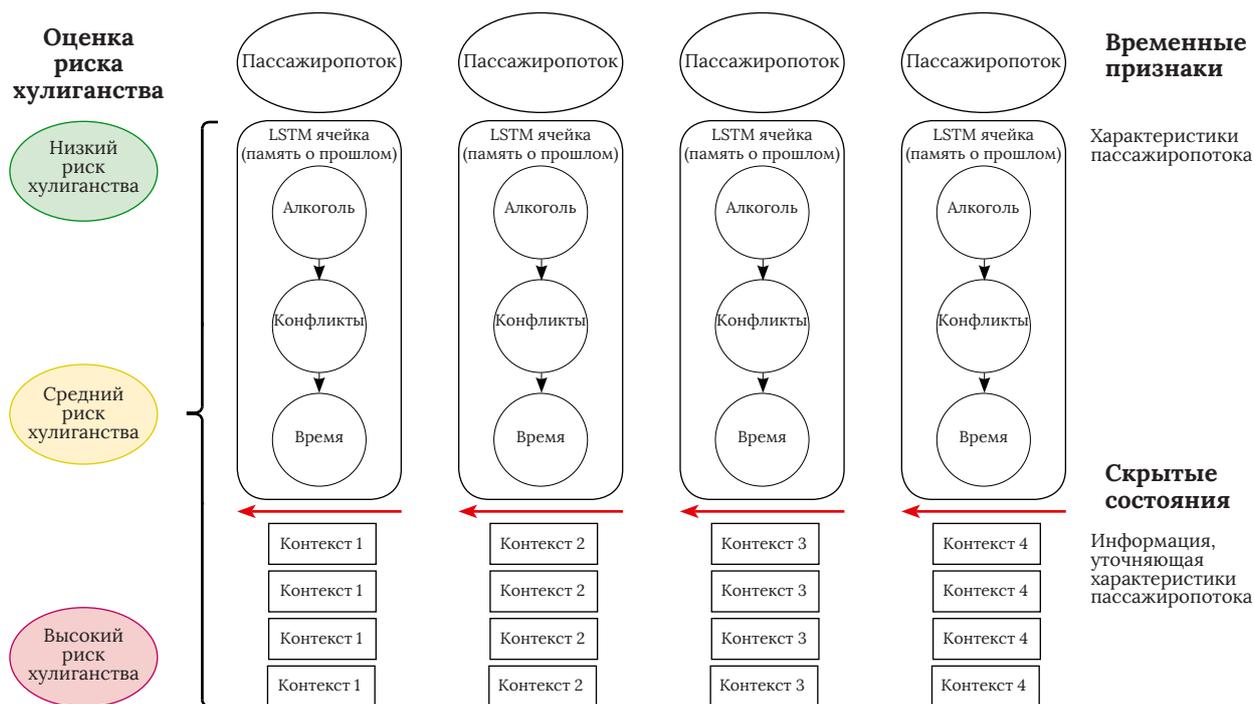


Рисунок 3. Пример архитектуры рекуррентной нейронной сети, ориентированной на прогнозирование риска хулиганства в самолете⁵
Figure 3. Example of a recurrent neural network architecture, designed for forecasting the risk of air rage

К преимуществам данных сетей следует отнести способность выявлять и использовать зависимость во времени и задержки между преступлением и его регистрацией. Ключевыми недостатками выступают чувствительность к ошибкам данных, длительность обучения и медленность при оценке сложных совокупностей признаков.

3. Временные сверточные сети (Temporal Convolutional Networks, TCN) – разновидность нейронных сетей, упрощающих и типизирующих временные последовательности (образующих «временные свертки») для повторяющихся событий. Временная свертка позволяет прогнозировать происшествия, правонарушения и преступления на основе причинно-следственных связей (causal convolutions), а также уже имеющихся данных о временных зависимостях между событиями [21; 10].

Они используются для прогнозирования событий, имеющих схожие обстоятельства и условия возникновения (нарушение правил дорожного движения, аварийность) и способны параллельно оценивать риск наступления на неограниченных участках (локациях) при соблюдении единства принципов обучения. Это достигается за счет наличия в структуре сети циклов, которые позволяют передавать скрытое состояние от одного временного шага к следующему.

⁵ Оценка риска хулиганства базируется на изучении характеристик пассажиропотока в конкретный момент времени, дополняемой признаками алкогольного опьянения и конфликтности.

Построение нейросети (рисунок 4) подобного типа позволяет выявлять признаки риска незаконного провоза пассажирами наркотических средств. Для этого в режиме реального времени осуществляется анализ видеоизображений пассажиров, находящихся на вокзале. Признаки риска (характеристики пассажира, его маршрута и багажа, аномальное поведение и иные параметры) нейросеть обрабатывает, сопоставляя их с ранее выявленными признаками у пассажиров, достоверно провозивших наркотические средства.

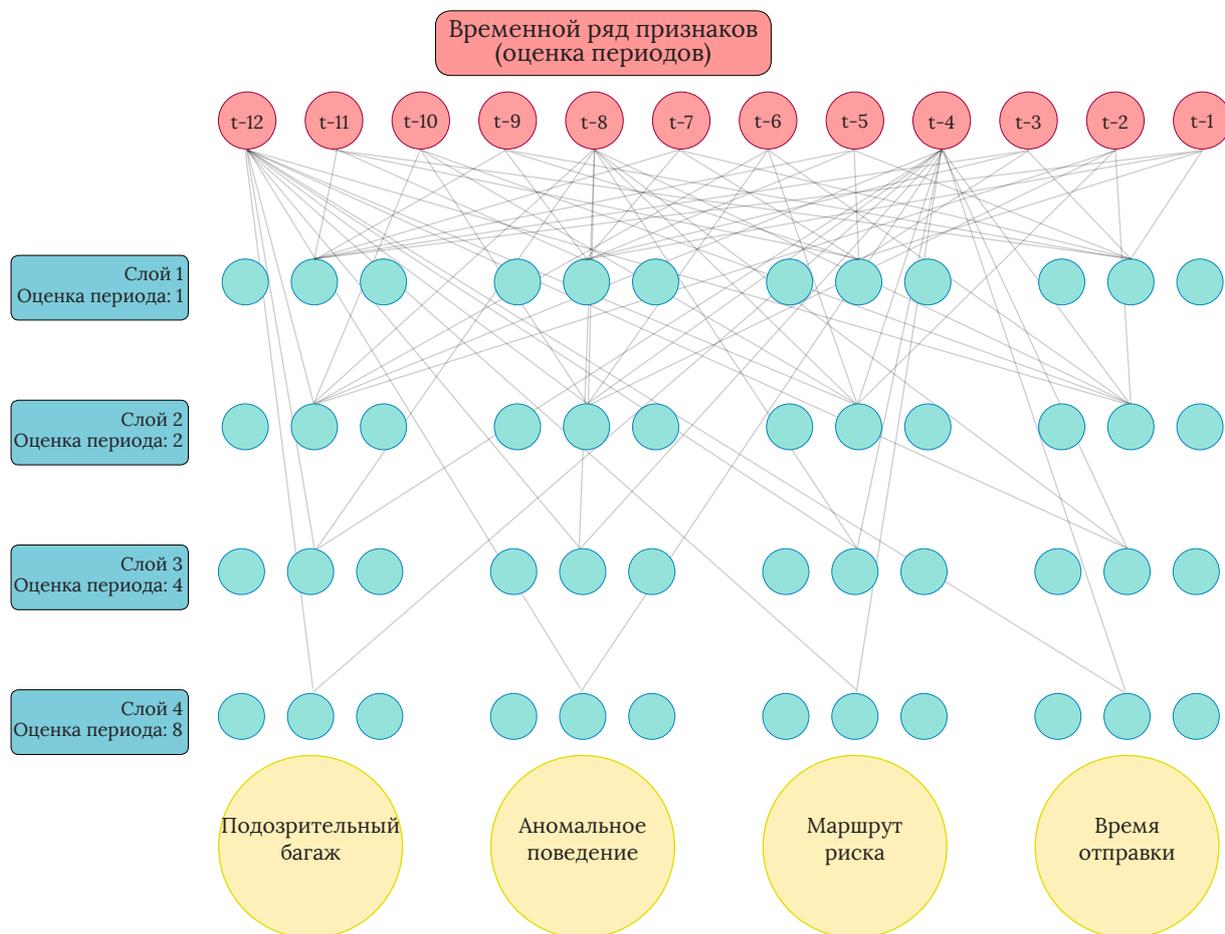


Рисунок 4. Пример архитектуры временной сверточной нейронной сети, ориентированной на оценку риска провоза наркотических средств⁶
Figure 4. Example of a temporal convolutional neural network architecture, designed to assess the risk of drug trafficking

Нейросеть обучается на регулярных маршрутах (наркотрафике), оценивая совпадения в приобретении билетов, признаки подозрительного поведения пассажиров во время нахождения на вокзале. Источниками данных выступают системы бронирования билетов, камеры видеонаблюдения, данные паспортного контроля, информация о происшествиях, оперативные сведения о пассажирах.

Достоинствами TCN выступают быстрота обучения, стабильность и точность прогнозирования. В числе недостатков – неспособность использовать прошлый опыт (анализ случаев) и самообучаться.

4. Графовые нейронные сети (Graph neural network, GNN) являются разновидностью нейронных сетей, обрабатывающих данные в виде графа.

Посредством графов воссоздаются отношения между различными объектами (отдельными лицами, группами лиц) в определенных местах (на вокзалах), в которых узлы графа описывают объекты (например, вокзалы), а ребра – отношения между ними (например, общение, содействие, взаимодействие). Благодаря представлению узлов и ребер в виде пространственных структур нейронная сеть прогнозирует риски криминализации на транспорте (например,

⁶ Приведена модель нейросети, оценивающей риск провоза наркотиков по 12 признакам (характеристикам внешности, багажа, поведения, маршрута и пр.). Входные данные обрабатываются путем многослойной свертки, сопоставляясь с критически значимыми признаками.

краж) исходя из зависимостей между ранее установленными фактами (например, кражами на различных вокзалах) (рисунок 5). Так GNN нейросеть позволяет противодействовать лицам, перемещающимся между вокзалами и совершающими кражи в различных регионах (гастролирующими) с определенной периодичностью. Вычисляя временную последовательность между кражами и сопоставляя ее с данными о пассажирах, которые находились на вокзале (либо лицах, которые перемещались между городами) GNN сеть устанавливает перечень подозреваемых лиц. С этой целью собираются и обобщаются сведения о пассажирах и их поведении с камер видеонаблюдения станций метро, авиа, железнодорожных и автовокзалов нескольких городов. Подобный информационный контур обеспечивает достаточный объем сведений для выявления лиц, подозреваемых в совершении краж багажа.

GNN: сетевой анализ краж вещей пассажиров на объектах транспорта

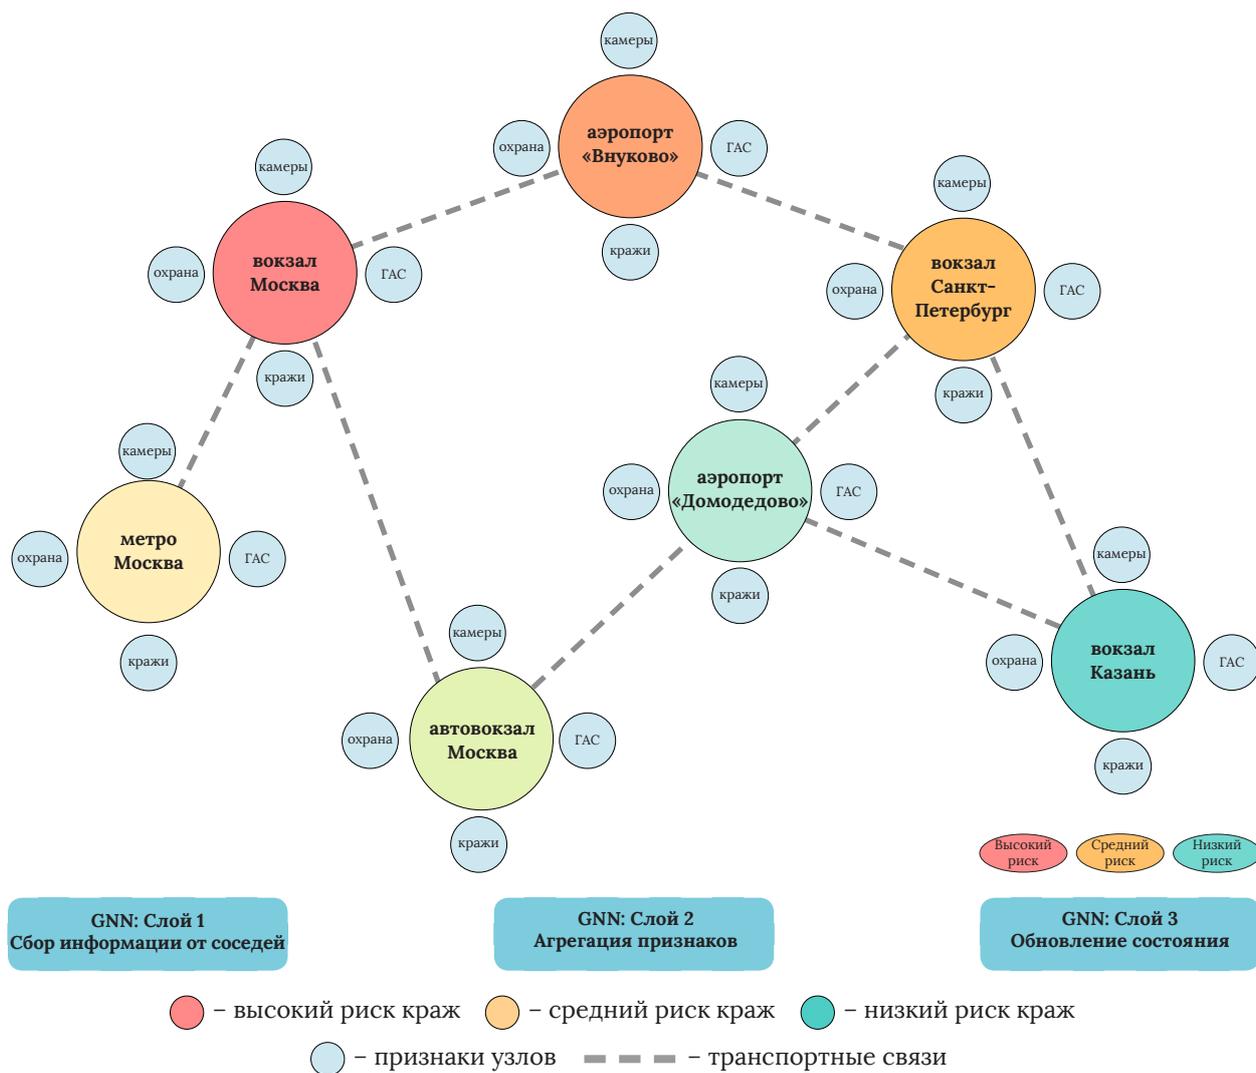


Рисунок 5. Пример организации графовой нейронной сети, ориентированной на оценку риска кражи багажа⁷

Figure 5. Example of a graph neural network architecture, designed to assess the risk of luggage theft

Применение нейросети для противодействия кражам вещей пассажиров позволяет сопоставлять преступления, совершенные на вокзалах разных городов, оценивая перемещение пассажиров и выявляя в поведении лиц схожие признаки.

Построение нейросетевой модели основывается на определении структуры графа (например, внутривокзальных зон – кассовый зал, зал ожидания, ресторан, зоны досмотра и пр.)

⁷ Представлена модель нейросети, соединяющей несколько транспортных узлов (вокзалов) по маршрутам пассажиропотока и определяющей риск совершения кражи исходя из (а) сведений о произошедших кражах и лицах, их совершивших; (б) обстоятельств и условий краж.

и выявления условий (например, пассажиропотока, освещенности, охраняемости и пр.). С учетом сведений о кражах формируется матрица оценки рисков (рисунок 6).

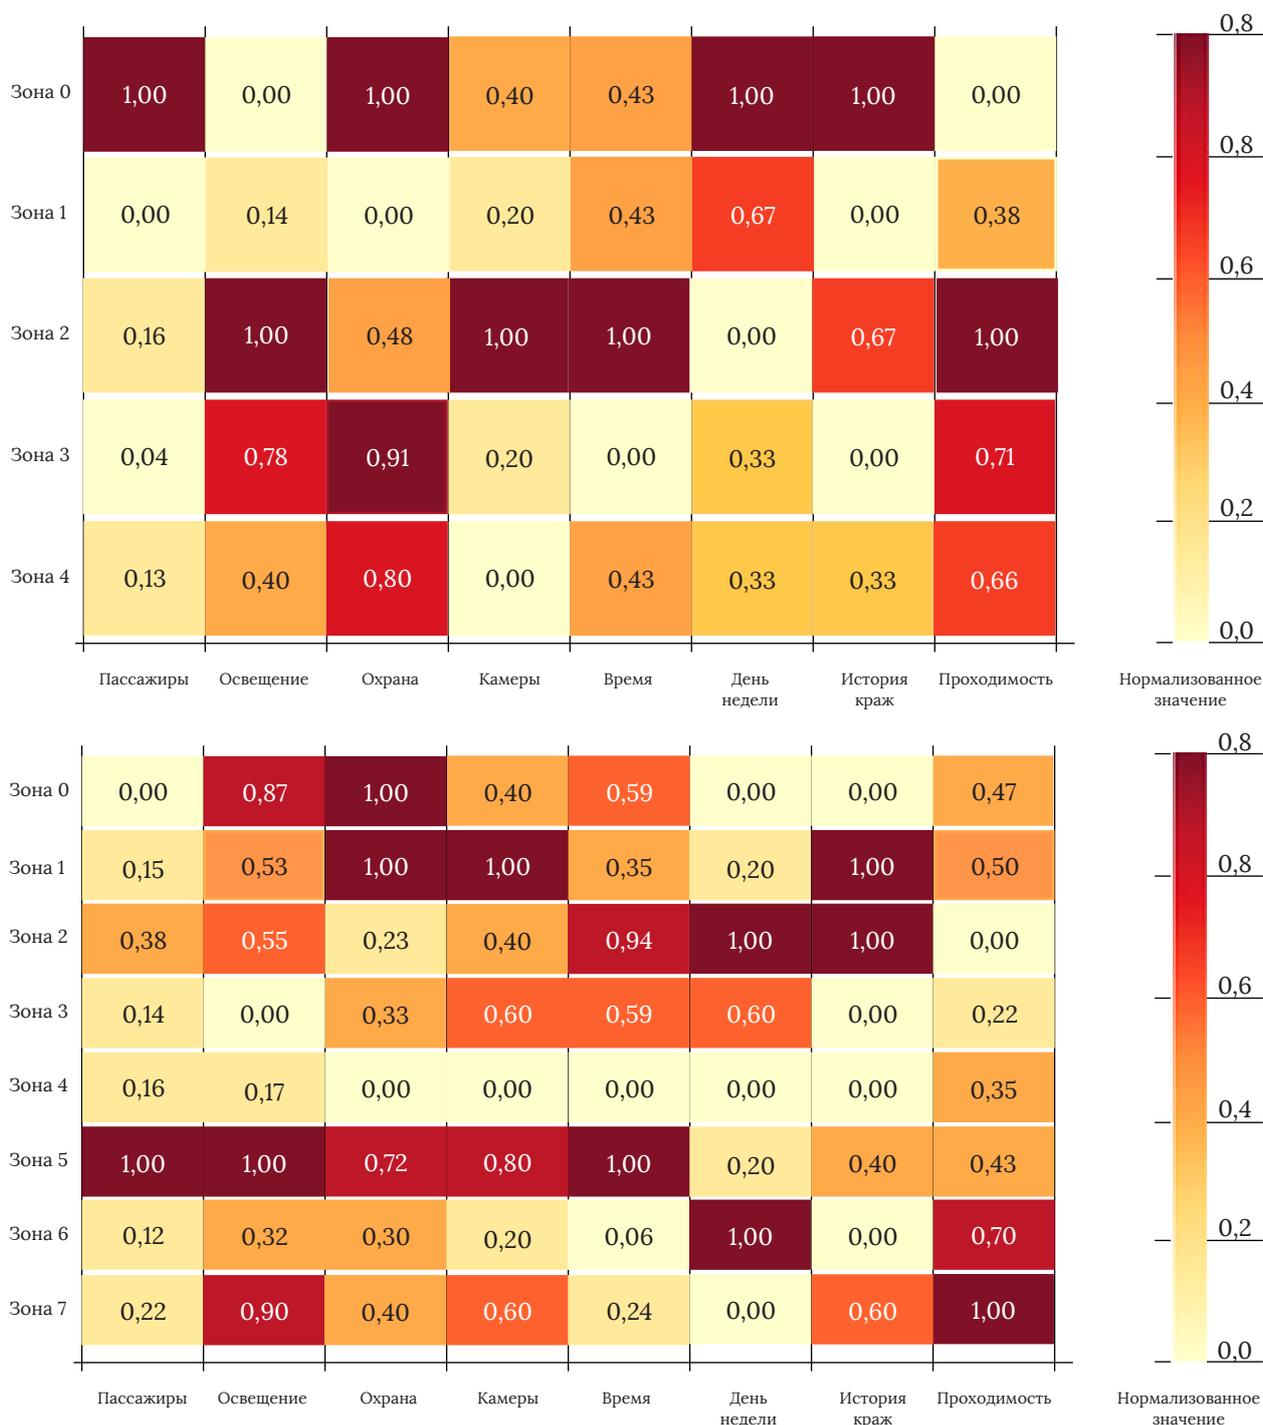


Рисунок 6. Матрицы оценки риска краж для двух вокзалов с делением на внутривокзальные зоны и оценкой рисков криминогенности каждой из них

Figure 6. Risk assessment matrices for theft at two railway stations, divided into in-station zones and an assessment of the crime risk for each

Матрица оценки рисков обобщается до графа – совокупности связей (весовых значений криминогенности) между узлами (зонами вокзала) и используется для обучения нейросети различению факторов риска. Коэффициенты варьируются в диапазоне от 0 (низкая криминогенная опасность) до 1 (высокая криминогенная опасность). В итоге нейросеть способна оценивать изменения риска криминогенности для каждой зоны вокзала в режиме реального времени по ранее определенным признакам.

В результате применения GNN нейросети возникает возможность вычисления и рисков криминальных посягательств, присущих конкретному объекту транспортной инфраструктуры (например, вокзалу), и возможностях их снижения.

К преимуществам нейросетей на основе графов относятся способность формировать топологии поведения преступников на объектах транспорта с учетом локальных характеристик, представлять отношения между объектами транспорта в пространстве с заданными характеристиками (отображать на картах характеристики криминогенности вокзалов).

К недостаткам относятся:

А. Высокая требовательность к качеству и правильности исходных данных, поскольку неточная или неполная информация может существенно исказить результаты прогнозирования.

Б. Сложность работы с временными рядами (прогнозирование событий во времени). Для моделирования данных, меняющихся со временем (пространственно-временных данных), требуются более сложные архитектуры, такие как пространственно-временные GNN, которые объединяют GNN с рекуррентными или сверточными сетями.

В. Неспособность GNN-моделей масштабировать выявленные закономерности на иные области, например модели криминогенности, разработанные применительно к определенным лицам (группам), транслировать на иные территории, области и пр.

С учетом выполненного обзора применения нейросетей в прогнозировании преступности ясно, что их развитие стало возможным благодаря тому, что исследователи уделяют приоритетное внимание разработке архитектуры нейросетевых моделей.

В настоящее время с помощью машинного обучения и обработки естественного языка появляется возможность выработать новые подходы, которые помогают управлять прогнозированием правонарушений и преступлений. Основанием для моделирования выступает параметрическая идентификация конкретных признаков преступлений, которые произошли в определенных районах. Эти признаки обширны и могут изменяться с течением времени в зависимости от таких переменных, как тип преступления, место совершения преступления и тенденции в области преступности [20].

Таким образом, использование нейросетей для прогнозирования преступлений представляет собой область познания, в которой технологии искусственного интеллекта применяются для анализа больших объемов данных, выявления закономерностей и предсказания возможной криминальной активности.

Нейросетевая модель прогнозирования правонарушений и преступлений

Алгоритм разработки нейросети представляет собой итерационный процесс, включающий в себя построение, оценку и использование модели.

В обобщенном виде он включает в себя четыре этапа (см. рисунок 7):

1. Получение, обработка и подготовка данных о правонарушениях и преступлениях на транспорте и объектах транспортной инфраструктуры.

2. Разработка архитектуры нейросети с учетом цели прогнозирования, задач и специфики данных о правонарушениях и преступлениях.

3. Обучение нейросети посредством различных стратегий, осуществления валидации и предотвращение переобучения.

4. Проверка нейросетевого прогноза оценкой свойств модели, устойчивости прогноза и его интерпретируемость.

Первый этап нацелен на сбор, подготовку и обработку данных о происшествиях, правонарушениях и преступлениях. К собираемой информации относятся, как правило, оперативные сведения (поступающие в режиме реального времени сведения о происшествиях), контекстные сведения, характеризующие обстоятельства происшествий (например, место и время, краткое сообщение о происшедшем); социальные сведения, характеризующие участников происшествия, их поведение и взаимодействие.

Очистка данных заключается в оценке соответствия сведений правилам их отображения, проверке качества представленных сведений, удалении неправильно представленной, ошибочной информации, дополнении или изменении сведений, заполнении пропусков.

Подготовка данных предполагает разметку (категоризацию, перевод в табличный вид), балансировку (сопоставление частот), разделение данных (выделение обучающей, валидирующей и тестовой подвыборки).

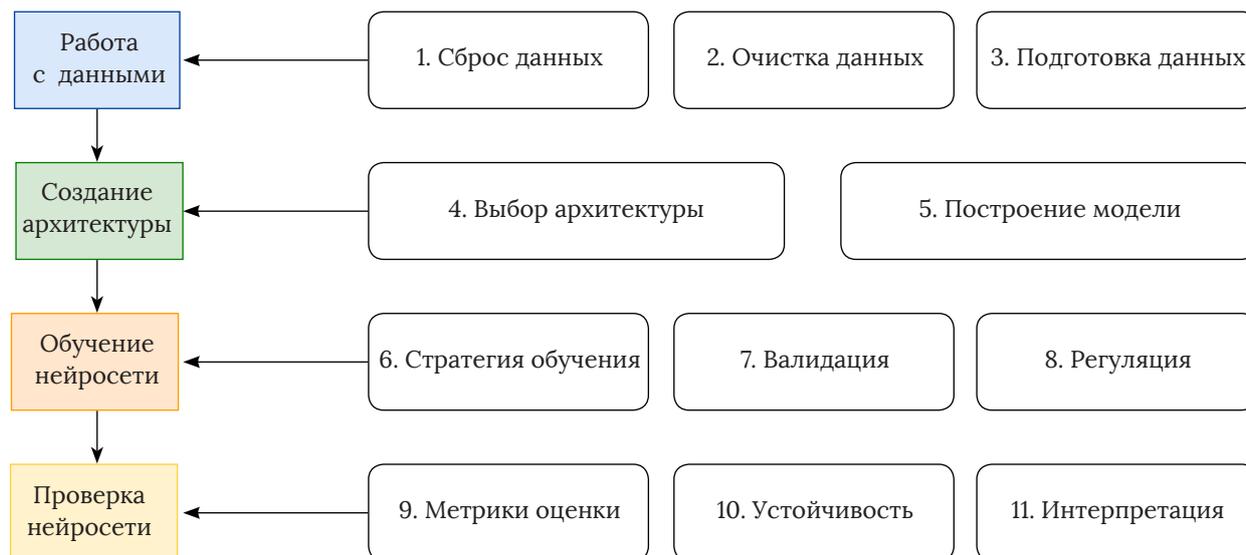


Рисунок 7. Алгоритм разработки нейросетевой модели прогнозирования правонарушений и преступлений

Figure 7. Algorithm for developing a neural network model for predicting offences and crimes

Второй этап алгоритма посвящен выбору архитектуры нейросети и ее построению.

Выбор архитектуры зависит от цели прогнозирования и задач, решаемых в ходе обработки данных, выбор предполагает использование четырех типов нейросети: MLP (многослойный перцептрон); RNN (рекуррентная нейронная сеть); TCN (временная сверточная сеть); GNN (графовая нейронная сеть).

Построение нейросети осуществляется посредством языков программирования (например, Python), конструкторов нейросетей, облачных и специализированных сервисов. Моделирование архитектуры сети зависит от цели и задач прогнозирования, а также типа нейросети, определяющей специализацию слоев. Определение количества слоев зависит от задачи прогнозирования и сложности поступающей информации. Следует учесть, что увеличение количества слоев уменьшает риски переобучения, однако требует больших ресурсов, чем модели с меньшим количеством слоев, и большего времени для обучения.

Третий этап алгоритма посвящен обучению модели. Обучение нейросети осуществляется посредством нескольких вариантов стратегий, зависящих от цели и характера данных. Базовым методом является обучение с учителем (Supervised Learning) (ранее определенным набором данных и правильными вариантами ответов). Ими могут быть сведения о признаках правонарушения или преступления, которые подкреплены правильным ответом. Альтернативой этому виду обучения является обучение без учителя (Unsupervised Learning), в рамках которого модели предъявляются данные, не содержащие правильных ответов в целях поиска закономерностей и взаимосвязей данных. Такое обучение снижает затраты на подготовку (разметку) информации, однако требует привлечения более опытного сотрудника, способного оценить качество обучения модели.

Помимо указанных методов обучения существуют также методы подкрепления (Reinforcement Learning), полуконтролируемого обучения (Semi-supervised Learning), представляющие собой комбинированные стратегии с частичным вовлечением оператора в обучение. Их применение обосновывается спецификой информации и целями обучения. В целом процесс обучения в зависимости от выбранного способа, а также платформы, на которой развернута нейросеть, может занять от нескольких минут до нескольких дней, в зависимости от сложности модели и объема данных.

Результаты обучения проверяются посредством валидации – проверки ее способности выполнять вычисления на неразмеченном (непредъявленном) фрагменте сведений. В результате валидации устанавливается возможность выявления нейросетью закономерностей, которые существуют в неизвестных для нее данных. Как правило, стратегия валидации предполагает выделение в выборке данных подмассива, содержащего необходимые сведения, но требует их обработки. Валидация осуществляется методами валидационной выборки и кросс-валидации, заключающимися в применении разных вариантов манипуляции с данными и формальной оценки параметров производительности нейросети.

Оценка производительности осуществляется для разных операций:

а) классификации (точность (accuracy) – количество правильно классифицированных примеров, полнота (recall) – количество положительных примеров, которые были правильно классифицированы, и F1 мера (F1-score) – среднее гармоническое между точностью и полнотой классификации;

б) регрессии (средняя абсолютная ошибка – значение разницы между предсказанными и фактическими значениями; среднеквадратическая ошибка – среднее квадратов разницы между предсказанными и фактическими значениями).

Данный комплекс параметров позволяет контролировать качество нейросети, оценивая риски ее переобучения, максимизировать производительность, а также сравнивать различные архитектуры нейросети между собой в целях выбора оптимального варианта.

Четвертый этап алгоритма заключается в оценке характеристик и интерпретации результатов. Его целью выступает оценка статистической значимости результатов модели и строится на предположении о том, что статистическая значимость удостоверяет стабильность прогноза и его устойчивость к различным факторам. Точность прогноза является важнейшей характеристикой, определяющей возможности его применения в оперативно-служебной деятельности органов внутренних дел Российской Федерации, равно как и в деятельности иных федеральных органов исполнительной власти. В Доктрине информационной безопасности Российской Федерации отмечается необходимость мониторинга, оценки состояния информационной безопасности и прогнозирования угроз, а также обеспечение достоверности и целостности информации, используемой в т. ч. в правоохранительной деятельности⁸.

Формальными критериями состоятельности прогноза правонарушений и преступлений являются показатели, отражающие соответствие модели и прогнозируемой ситуации:

– показатели совпадения – индикаторы, которые имеют высокую степень корреляции и (или) однонаправленную динамику;

– запаздывающие индикаторы – показатели, которые формируются после тех или иных изменений в изучаемом объекте;

– циклические индикаторы – показатели, которые с различной степенью опережения либо без нее характеризуют переход наблюдаемой системы из одной циклической фазы в другую;

– контрциклические индикаторы – показатели, улавливающие разнонаправленность системной динамики⁹.

В настоящее время оценка состоятельности опирается на формальные (математико-статистические), содержательные (теоретические) и практические (экспертные) виды оценок.

Возможности применения нейросетевых моделей для прогнозирования преступлений основывается на оценке их состоятельности. Для нейросетевой модели важную роль играет выбор не только цели, задач и параметров прогнозирования, но и задание внутренней структуры нейронных сетей – числа скрытых слоев и количества нейронов в каждом скрытом слое. Для оценки модели применяются результаты оценки среднеквадратичной ошибки между представленными для анализа данными и результатами прогнозирования. При этом, как отмечает В. Ю. Петрова, построенная модель должна быть адекватна реальной системе и условиям, в которых ее предполагается использовать. Если полученная модель не удовлетворяет какому-либо критерию, то повторяются предыдущие этапы процедуры идентификации [22].

В заключение следует отметить, что алгоритм прогнозирования правонарушений и преступлений с помощью нейросетевых технологий нацелен на унификацию практик их разработки, учитывая разнообразие методов прогнозирования и потребность их адаптации.

3 Заключение

В статье показано, что в деятельности органов внутренних дел Российской Федерации и правоохранительных органов зарубежных стран нейросетевые технологии активно применяются для прогнозирования правонарушений и преступлений в режиме охраны общественного порядка и общественной безопасности и в аспекте криминологического прогнозирования. Рассматриваются преимущества и недостатки современных моделей прогнозирования преступности, акцентируется внимание на актуальности использования таких технологий в правоохранительных

⁸ Об утверждении Доктрины информационной безопасности Российской Федерации : Указ Президента Российской Федерации от 5 декабря 2016 г. № 646 // СЗ РФ. 2016. № 50. Ст. 7074.

⁹ Цит. по: Ларина Е. С., Овчинский В. С. Искусственный интеллект большие данные. Преступность. Москва : Книжный мир, 2018. С. 291–293.

органах. Отмечается, что современный арсенал нейросетевых методов прогнозирования, применимых для оценки риска совершения правонарушений и преступлений, составляют четыре метода – многослойный перцептрон (MLP), рекуррентная нейронная сеть (RNN), временная сверточная сеть (TCN), графовая нейронная сеть (GNN). На основе их методологии может быть разработана нейросетевая модель прогнозирования правонарушений и преступлений. Внимание уделяется способности технологий обработки больших данных и выявлению закономерностей, которые позволяют улучшать методы криминологического прогнозирования. С учетом изложенного формулируется алгоритм прогноза правонарушений и преступлений, приводятся примеры нейросетевых моделей, алгоритмов машинного обучения и статистических методов, используемых для решения задач прогнозирования правонарушений и преступлений на транспорте.

Теоретические и прикладные перспективы использования материала статьи заключаются в их применении для повышения осведомленности сотрудников органов внутренних дел Российской Федерации о современных методах разработки нейросетевых моделей, их валидации и внедрении в оперативно-служебную деятельность; применении нейросетевых моделей в целях прогнозирования правонарушений и преступлений; совершенствовании имеющихся нейросетевых методов прогнозирования криминогенной обстановки на транспорте и объектах транспортной инфраструктуры.

Список источников

1. Mishra R. K. [et al.]. Analysis of criminal landscape by utilizing statistical analysis and deep learning techniques // *Journal of Applied Security Research*. 2024. Vol. 19, № 4. P. 560–585.
2. Zeng M., Mao Y., Wang C. The relationship between street environment and street crime: A case study of Pudong New Area, Shanghai, China // *Cities*. 2021. Vol. 112. P. 103143. <https://doi.org/10.1016/j.cities.2021.103143>
3. Johnson T. L. [et al.]. Police facial recognition applications and violent crime control in US cities // *Cities*. 2024. Vol. 155. P. 105472. <https://doi.org/10.1016/j.cities.2024.105472>
4. Kim G. [et al.]. Crime Mapping in Urban Environments Using Explainable AI: A Case Study of Daegu, Korea // *Sustainable Cities and Society*. 2025. Vol. 130. P. 106507. <https://doi.org/10.1016/j.scs.2025.106507>
5. Yang S. [et al.]. The impact of surveillance cameras and community safety activities on crime prevention: Evidence from Kakogawa City, Japan // *Sustainable Cities and Society*. 2024. Vol. 115. P. 105858. <https://doi.org/10.1016/j.scs.2025.106507>
6. Захватов И. Ю., Пчоловский М. Н. Прогнозирование как элемент информационно-аналитического обеспечения деятельности органов внутренних дел / Высшая школа: научные исследования : материалы Межвузовского международного конгресса, г. Москва, 24 июня 2021 г. Москва : Инфинити, 2021. С. 14–24.
7. Clavell G. G. Exploring the ethical, organizational and technological challenges of crime mapping: A critical approach to urban safety technologies // *Ethics and Information Technology*. 2018. Vol. 20, № 4. P. 265–277. <https://doi.org/10.1007/s10676-018-9477>
8. Saunders J., Hunt P., Hollywood J. S. Predictions put into practice: a quasi-experimental evaluation of Chicago's predictive policing pilot // *Journal of experimental criminology*. 2016. Vol. 12, № 3. P. 347–371. <https://doi.org/10.1007/s11292-016-9272-0>
9. Ansfield B. The broken windows of the Bronx: Putting the theory in its place // *American Quarterly*. 2020. Vol. 72, № 1. P. 103–127. <https://doi.org/10.1353/aq.2020.0005>
10. Mukherjee K. [et al.]. Uncovering spatial patterns of crime: A case study of Kolkata // *Crime Prevention and Community Safety*. 2024. Vol. 26, № 1. P. 47–90. <https://doi.org/10.1057/s41300-024-00198-4>
11. Кайбичев И. А., Кайбичева Е. И. Математическое моделирование временного ряда количества преступлений в России // *Вестник экономики, управления и права*. 2019. № 4 (49). С. 80–85.
12. Шалагин А. Е., Шаранова А. Д. Криминологическое прогнозирование и планирование в деятельности органов внутренних дел // *Вестник экономики, права и социологии*. 2017. № 2. С. 127–130.
13. Massarelli C., Uricchio V. F. The contribution of open-source software in identifying environmental crimes caused by illicit waste management in urban areas // *Urban Science*. 2024. Vol. 8, № 1. P. 21. <https://doi.org/10.3390/urbansci8010021>
14. Marciniak D. Algorithmic policing: An exploratory study of the algorithmically mediated construction of individual risk in a UK police force // *Policing and society*. 2023. Vol. 33, № 4. P. 449–463. <https://doi.org/10.1080/10439463.2022.2144305>
15. Суходолов А. П., Бычкова А. М. Искусственный интеллект в противодействии преступности, ее прогнозировании, предупреждении и эволюции // *Всероссийский криминологический журнал*. 2018. Т. 12, № 6. С. 753–766. [https://doi.org/10.17150/2500-4255.2018.12\(6\).753-766](https://doi.org/10.17150/2500-4255.2018.12(6).753-766)
16. Клейменов М. П. Уголовно-правовое прогнозирование : монография. Томск : Национальный исследовательский Томский государственный университет, 1991. 167 с.
17. Киселев А. А. Сезонность преступности как объект криминологического изучения // *Правовая культура*. 2020. № 2 (41). С. 139–150.
18. Ульянов А. Д., Власов Б. Е. Теоретико-методологическое обеспечение аналитической работы в органах внутренних дел в современных условиях // *Труды Академии управления МВД России*. 2023. № 1 (65). С. 24–31. <https://doi.org/10.24412/2072-9391-2023-465-24-31>
19. Bifari E. [et al.]. Text mining and machine learning for crime classification: using unstructured narrative court documents in police academic // *Cogent Engineering*. 2024. Vol. 11, № 1. P. 2359850. <https://doi.org/10.1080/23311916.2024.2359850>
20. Dakalbab F. [et al.]. Artificial intelligence & crime prediction: A systematic literature review // *Social Sciences & Humanities Open*. 2022. Vol. 6, № 1. P. 100342. <https://doi.org/10.1016/j.ssaho.2022.100342>
21. Lee W. D. [et al.]. The influence of intra-daily activities and settings upon weekday violent crime in public spaces in Manchester, UK // *European Journal on Criminal Policy and Research*. 2021. Vol. 27, № 3. P. 375–395. <https://doi.org/10.1007/s10610-020-09456-1>

22. Петрова В. Ю. Роль прогнозирующих моделей в управлении органами внутренних дел (на примере преступлений, связанных с легализацией преступных доходов) // Вестник Владимирского юридического института. 2013. № 2 (27). С. 107–109.

References

1. Mishra R. K. [et al.]. Analysis of criminal landscape by utilizing statistical analysis and deep learning techniques // Journal of Applied Security Research. 2024. Vol. 19, № 4. P. 560–585.
2. Zeng M., Mao Y., Wang C. The relationship between street environment and street crime: A case study of Pudong New Area, Shanghai, China // Cities. 2021. Vol. 112. P. 103143. <https://doi.org/10.1016/j.cities.2021.103143>
3. Johnson T. L. [et al.]. Police facial recognition applications and violent crime control in US cities // Cities. 2024. Vol. 155. P. 105472. <https://doi.org/10.1016/j.cities.2024.105472>
4. Kim G. [et al.]. Crime Mapping in Urban Environments Using Explainable AI: A Case Study of Daegu, Korea // Sustainable Cities and Society. 2025. Vol. 130. P. 106507. <https://doi.org/10.1016/j.scs.2025.106507>
5. Yang S. [et al.]. The impact of surveillance cameras and community safety activities on crime prevention: Evidence from Kakogawa City, Japan // Sustainable Cities and Society. 2024. Vol. 115. P. 105858. <https://doi.org/10.1016/j.scs.2025.106507>
6. Zahvatov I. Yu., Pcholvskij M. N. Prognozirovanie kak element informacionno-analiticheskogo obespecheniya deyatel'nosti organov vnutrennih del / Vysshaya shkola: nauchnye issledovaniya : materialy Mezhdunarodnogo kongressa, g. Moskva, 24 iyunya 2021 g. Moskva : Infiniti, 2021. S. 14–24.
7. Clavell G. G. Exploring the ethical, organizational and technological challenges of crime mapping: A critical approach to urban safety technologies // Ethics and Information Technology. 2018. Vol. 20, № 4. P. 265–277. <https://doi.org/10.1007/s10676-018-9477>
8. Saunders J., Hunt P., Hollywood J. S. Predictions put into practice: a quasi-experimental evaluation of Chicago's predictive policing pilot // Journal of experimental criminology. 2016. Vol. 12, № 3. P. 347–371. <https://doi.org/10.1007/s11292-016-9272-0>
9. Ansfield B. The broken windows of the Bronx: Putting the theory in its place // American Quarterly. 2020. Vol. 72, № 1. P. 103–127. <https://doi.org/10.1353/aq.2020.0005>
10. Mukherjee K. [et al.]. Uncovering spatial patterns of crime: A case study of Kolkata // Crime Prevention and Community Safety. 2024. Vol. 26, № 1. P. 47–90. <https://doi.org/10.1057/s41300-024-00198-4>
11. Kajbichev I. A., Kajbicheva E. I. Matematicheskoe modelirovanie vremennogo ryada kolichestva prestuplenij v Rossii // Vestnik ekonomiki, upravleniya i prava. 2019. № 4 (49). S. 80–85.
12. Shalagin A. E., Sharapova A. D. Kriminologicheskoe prognozirovanie i planirovanie v deyatel'nosti organov vnutrennih del // Vestnik ekonomiki, prava i sociologii. 2017. № 2. S. 127–130.
13. Massarelli C., Uricchio V. F. The contribution of open-source software in identifying environmental crimes caused by illicit waste management in urban areas // Urban Science. 2024. Vol. 8, № 1. P. 21. <https://doi.org/10.3390/urbansci8010021>
14. Marciniak D. Algorithmic policing: An exploratory study of the algorithmically mediated construction of individual risk in a UK police force // Policing and society. 2023. Vol. 33, № 4. P. 449–463. <https://doi.org/10.1080/10439463.2022.2144305>
15. Suhodolov A. P., Bychkova A. M. Iskusstvennyj intellekt v protivodejstvii prestupnosti, ee prognozirovanii, preduprezhdenii i evolyucii // Vserossijskij kriminologicheskij zhurnal. 2018. T. 12, № 6. S. 753–766. [https://doi.org/10.17150/2500-4255.2018.12\(6\).753-766](https://doi.org/10.17150/2500-4255.2018.12(6).753-766)
16. Klejmenov M. P. Ugolovno-pravovoe prognozirovanie : monografiya. Tomsk : Nacional'nyj issledovatel'skij Tomskij gosudarstvennyj universitet, 1991. 167 s.
17. Kiselev A. A. Sezonnost' prestupnosti kak ob'ekt kriminologicheskogo izucheniya // Pravovaya kul'tura. 2020. № 2 (41). S. 139–150.
18. Ul'yanov A. D., Vlasov B. E. Teoretiko-metodologicheskoe obespechenie analiticheskoy raboty v organah vnutrennih del v sovremennykh usloviyah // Trudy Akademii upravleniya MVD Rossii. 2023. № 1 (65). S. 24–31. <https://doi.org/10.24412/2072-9391-2023-465-24-31>
19. Bifari E. [et al.]. Text mining and machine learning for crime classification: using unstructured narrative court documents in police academic // Cogent Engineering. 2024. Vol. 11, № 1. P. 2359850. <https://doi.org/10.1080/23311916.2024.2359850>
20. Dakalbab F. [et al.]. Artificial intelligence & crime prediction: A systematic literature review // Social Sciences & Humanities Open. 2022. Vol. 6, № 1. P. 100342. <https://doi.org/10.1016/j.ssaho.2022.100342>
21. Lee W. D. [et al.]. The influence of intra-daily activities and settings upon weekday violent crime in public spaces in Manchester, UK // European Journal on Criminal Policy and Research. 2021. Vol. 27, № 3. P. 375–395. <https://doi.org/10.1007/s10610-020-09456-1>
22. Petrova V. Yu. Rol' prognoziryuyushchih modelej v upravlenii organami vnutrennih del (na primere prestuplenij, svyazannyh s legalizaciej prestupnyh dohodov) // Vestnik Vladimirskogo yuridicheskogo instituta. 2013. № 2 (27). S. 107–109.

Авторами внесен равный вклад в написание статьи.
Авторы заявляют об отсутствии конфликта интересов.

The authors have made an equal contribution to the writing of the article.
The authors declare no conflicts of interests.