

Научная статья

УДК 004.94; DOI: 10.61260/2304-0130-2026-2-81-89

ИНТЕГРАЦИЯ СИТУАЦИОННЫХ ФАКТОРОВ И ГЕТЕРОГЕННЫХ ДАННЫХ ДЛЯ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ АНАЛИЗА ДОРОЖНО-ТРАНСПОРТНЫХ ПРОИСШЕСТВИЙ

✉ Удайб Масар Абед;

Тютюнник Вячеслав Михайлович.

Тамбовский государственный технический университет, Тамбов, Россия

✉ masar.uthaib2018@gmail.com

Аннотация. Дорожно-транспортные происшествия (ДТП) представляют собой значительную угрозу для общественной безопасности и транспортных сетей, что требует применения передовых методов моделирования для изучения их причин, тенденций и последствий. Сложность моделирования ДТП обусловлена необходимостью объединения различных источников данных, включая пространственно-временные изменения, переменные окружающей среды, характеристики автомобилей и водителей, элементы инфраструктуры. Недавние прорывы в машинном обучении, включая графовые нейронные сети, модели глубокого обучения на основе механизма внимания и гибридные древовидные классификаторы, повысили точность прогнозирования и интерпретируемость. Эти методы используют гетерогенные данные для обеспечения прогнозирования аварий в реальном времени, оценки тяжести и выявления наиболее проблемных зон. Тем не менее, остаются препятствия, такие как разреженность данных, дисбаланс классов и интерпретируемость модели. В данной статье рассмотрены современные подходы к моделированию аварий, выявлено влияние разнообразной информации на установления частоты и тяжести аварий, что позволяет повысить безопасность дорожного движения, оптимизировать управление дорожным движением и усовершенствовать подходы и технологии предотвращения аварий. Определены перспективные направления исследований в этом направлении моделирования и машинного обучения: интеграция гетерогенных данных, использование методов причинно-следственного машинного обучения и системы поддержки принятия решений в реальном времени.

Ключевые слова: моделирование, гетерогенная информация, дорожно-транспортные происшествия, машинное обучение

Для цитирования: Удаиб М.А., Тютюнник В.М. Интеграция ситуационных факторов и гетерогенных данных для повышения эффективности анализа дорожно-транспортных происшествий // Природные и техногенные риски (физико-математические и прикладные аспекты). 2026. № 2 (58). С. 81-89. DOI: 10.61260/2304-0130-2026-2-81-89

Scientific article

INTEGRATING SITUATIONAL FACTORS AND HETEROGENEOUS DATA FOR ENHANCED TRAFFIC ACCIDENT ANALYSIS

✉ Masar A. Uthaib;

Viacheslav M. Tyutyunnik.

Tambov State Technical University, Tambov, Russia

✉ masar.uthaib2018@gmail.com

Abstract. Road traffic accidents (RTAs) pose a significant threat to public safety and transportation networks, requiring advanced modeling techniques to study their causes, trends, and consequences.

© Санкт-Петербургский университет ГПС МЧС России, 2026

The complexity of RTAs modeling stems from the need to integrate diverse data sources, including spatiotemporal changes, environmental variables, vehicle and driver characteristics, and infrastructure elements. Recent advances in machine learning, including graph neural networks, attention-based deep learning models, and hybrid tree classifiers, have improved prediction accuracy and interpretability. These methods leverage heterogeneous data to provide real-time crash prediction, severity assessment, and identification of problem areas. However, obstacles remain, such as data sparsity, class imbalance, and model interpretability. This article reviews modern approaches to RTAs modeling and identifies the impact of diverse information on crash frequency and severity estimates, thereby improving road safety, optimizing traffic management, and refining crash prevention approaches and technologies. Promising research directions in this area of modeling and machine learning are identified: integration of heterogeneous data, use of causal machine learning methods and real-time decision support systems.

Keywords: modeling, heterogeneous information, traffic accidents, machine learning

For citation: Uthaib M.A., Tyutyunnik V.M. Integrating situational factors and heterogeneous data for enhanced traffic accident analysis // Prirodnye i tekhnogennye riski (fiziko-matematicheskie i prikladnye aspekty) = Natural and man-made risks (physico-mathematical and applied aspects). 2026. № 2 (58). P. 81-89. DOI: 10.61260/2304-0130-2026-2-81-89

Введение

Дорожно-транспортные происшествия (ДТП) представляют собой серьёзную угрозу общественной безопасности и транспортной инфраструктуре во всём мире. Сложность моделирования ДТП обусловлена необходимостью варьирования множеством данных из разных источников: пространственно-временными колебаниями, условиями окружающей среды, поведением человека, характеристиками транспортных средств, многообразием инфраструктур и частотой аварий [1, 2].

Достижения в области машинного обучения и анализа больших данных позволили разработать креативные методы преодоления этих трудностей [3-5]. В данной статье рассмотрены некоторые модели ДТП с акцентом на разнообразные информационные и ситуационные аспекты, а также проанализированы данные из ряда исследовательских работ других авторов [6, 7].

Цель данного исследования – проанализировать многочисленные данные о повышении эффективности анализа динамики ДТП и уровень поддержки принятия решений по безопасности дорожного движения, показать перспективы исследований в области распознавания образов на основе данных о ДТП.

Основные методы моделирования дорожно-транспортных происшествий

К настоящему времени в мировой практике наработано большое количество моделей и методов для фиксирования, оценки, классификации, распознавания участников ДТП и их предотвращения. Рассмотрим наиболее эффективные из них.

Самыми современными являются графовые нейронные сети (GNN) для пространственно-временного анализа, которые стали эффективным инструментом для моделирования ДТП, поскольку они учитывают пространственные и временные взаимодействия в дорожных сетях. Метод GraphSAGE использовался для прогнозирования аварий с достаточно высокой точностью, достигнув средней абсолютной ошибки менее 22% и показатель эффективности, который используют для оценки моделей классификации (AUROC), выше 87% [8]. В этом методе используют модели конфигурации дорожной сети и данные об объёме трафика, на основе чего получают сведения об опасностях аварий.

Модели архитектуры глубокого обучения, основанные на механизме внимания, используют для решения проблемы пространственно-временной изменчивости данных о дорожном движении. Причинно-следственная пространственно-временная многографовая свёрточная сеть (ASTMGCN) демонстрирует использование многографовых свёрточных операторов и механизмов внимания для эффективного захвата динамических пространственных и временных характеристик и точного прогнозирования трафика [9]. Этот метод не только повышает точность прогнозирования, но и улучшает интерпретируемость модели, так как используем технологию калибровки неопределённости с учётом разрежённости.

Метод объединения древовидных и глубоких моделей обучения (гибридные модели) также продемонстрировали успех в прогнозировании ДТП. Такие методы, как AdaBoost, XGBoost и Random Forest, при интеграции с моделями глубокого обучения достигли высоких показателей производительности, включая точность, полноту и F1-меру (метрика оценки качества моделей классификации, представляющая собой гармоническое среднее между точностью и полнотой), превышающие 90% [10]. Эти модели очень эффективны в обработке несбалансированных наборов данных, характеризующихся редкостью инцидентов.

Метод многомодальных крупномасштабных моделей для углублённого анализа (AccidentGPT) синтезирует данные из множества источников, включая восприятие окружающей среды V2X (Vehicle-to-Everything – транспортное средство для всего), чтобы предоставить комплексную методологию анализа и предотвращения аварий [11]. Эта модель обеспечивает оповещения об опасности в режиме реального времени, предотвращение столкновений и оценку ответственности после инцидента, что делает её всесторонним инструментом для обеспечения безопасности дорожного движения.

Для распознавания образов после применения перечисленных методов требуется учитывать достаточное количество факторов, которые обычно сопровождают ДТП и требует рассматривать и учитывать в моделях разнообразную гетерогенную информацию о ДТП.

Гетерогенная информация о дорожно-транспортных происшествиях

ДТП демонстрируют значительную пространственно-временную изменчивость, то есть их частота и тяжесть колеблется в зависимости от местоположения и временных интервалов. Модель географически и временно взвешенной регрессии (GTWR) эффективно отражает эти различия, демонстрируя, что такие элементы, как насыщенность трафика и конфигурация дорожной сети, оказывают уникальное влияние на аварии в различных пространственных и временных контекстах [12, 13].

Созданная человеком искусственная среда, включающая многообразие различных дорог, землепользование и плотность городской застройки, существенно влияет на тяжесть ДТП. Исследования показывают, что в мегаполисах, характеризующихся разнообразным землепользованием, как правило, наблюдается повышенный уровень аварийности, в то время как в пригородных или сельских районах наблюдается обратная зависимость [11–13]. Эти выводы подчёркивают необходимость учёта географической изменчивости при моделировании.

Погодные условия, включая дождь, снег и туман, существенно повышают вероятность ДТП. Алгоритмы машинного обучения, использующие метеорологические данные, показывают, что неблагоприятные погодные условия усугубляют тяжесть аварий, особенно в сочетании с такими переменными, как время суток и тип дороги. Обледенелые дороги, стоячая вода и недостаточное освещение повышают тяжесть аварий сверх обычного уровня, при этом модели глубоких нейронных сетей демонстрируют высокую точность в прогнозировании катастрофических столкновений [13]. Более того, методы машинного обучения показали, что метеорологические элементы, такие как скорость и температура ветра, являются значимыми факторами при прогнозировании продолжительности и тяжести аварий [14]. Исследование [15] подтверждает, что погода в сочетании с местоположением и

типом дороги существенно влияет на ДТП, при этом модели машинного обучения эффективно сопоставляют характеристики аварий с уровнями тяжести. Эти результаты подчёркивают необходимость включения метеорологических данных в стратегии управления дорожным движением для снижения риска аварий.

Тип транспортного средства, поведение водителя и характеристики участников дорожного движения являются важными элементами моделирования аварий. С участием мотоциклов аварии чаще происходят в определённых городских регионах, тогда как столкновения грузовиков и легковых автомобилей преобладают на автомагистралях. Передовые методы машинного обучения, включая географически взвешенные нейронные сети (GWNN), использовались для анализа географических различий в тяжести аварий, выявляя в качестве значимых факторов риска травм такие переменные, как тип транспортного средства, состояние водителя и место аварии [16]. Кроме того, исследования с использованием глубокого обучения и нейронных сетей с радиальными базисными функциями подчеркнули значимость данных о вождении в реальном времени, указывая на то, что динамика транспортного средства и поведение водителя существенно влияют на уровень риска аварий [17]. Модели машинного обучения использовались для оценки тяжести травм водителей, указывая на то, что такие характеристики, как безрассудное вождение, превышение скорости и тип столкновения, значительно влияют на исход аварий [18]. Эти выводы получены с помощью методов кластеризации, поиска ассоциативных правил и прогнозной аналитики, подчёркивая необходимость обязательного учёта характеристик транспортного средства и водителя.

Применение моделей дорожно-транспортных происшествий

Методы машинного обучения оценивают ретроспективные данные об авариях, состояние дорог, метеорологические факторы и плотность движения для прогнозирования зон повышенного риска. Модели градиентного бустинга и случайного леса использованы для определения регионов, подверженных авариям, и внедрения превентивных стратегий [19].

Системы мониторинга в реальном времени и раннего предупреждения снижают частоту аварий. Байесовские сетевые модели предлагают динамические оценки риска аварий и генерируют сигналы тревоги для предотвращения столкновений [20]. Модели географических информационных систем (ГИС) облегчают визуализацию мест с высокой аварийностью, интеграцию данных о транспортном потоке и оптимизацию развития инфраструктуры. Эти модели помогают градостроителям создавать более безопасные переходы и улучшать дорожные сети [21].

Классификаторы машинного обучения, такие как машины опорных векторов (SVM) и случайный лес, классифицируют тяжесть несчастных случаев как смертельную, серьёзную или незначительную. Они помогают службам экстренной помощи расставлять приоритеты в реагировании и оптимизировать распределение медицинских ресурсов [22]. Передовые архитектуры глубокого обучения, такие как свёрточные рекуррентные нейронные сети (CRNN), обеспечивают прогнозирование аварий в реальном времени и оповещения водителей, снижают количество аварий за счёт изменения действий водителя посредством прогнозной оценки риска.

Препятствия в моделировании дорожно-транспортных происшествий

Относительная редкость аварийных событий затрудняет разработку устойчивых моделей прогнозирования. Для преодоления дисбаланса классов использованы такие методы, как синтетическое генерирование данных (SMOTE) и адаптивная синтетическая выборка для несбалансированных данных (ADASYN), что повысило эффективность модели на данных об авариях, происходящих нечасто [9].

Разнообразные эффекты элементов в различных географических и временных контекстах требуют моделей, учитывающих пространственно-временную неоднородность. Для решения этой проблемы созданы перспективные модели: географическая и временная взвешенная регрессия (Geographical and Temporal Weighted Regression, GTWR) и географически и временной взвешенный анализ пропорциональных рисков (Geographical and Temporal Weighted Proportional Hazard analysis, GTWPH) [23].

Несмотря на эффективность моделей глубокого обучения, их недостаточная интерпретируемость может препятствовать применению в практических сценариях. Для анализа результатов работы моделей обычно используется метод добавок Шепли (SHapley Additive exPlanations, SHAP) – метод интерпретации машинного обучения, который объясняет вклад каждого признака в предсказание конкретного наблюдения. Он основан на концепции значений Шепли из теории кооперативных игр и позволяет получить представление о факторах, влияющих на прогнозы [24, 25].

Перспективы исследований

Проведённый анализ показывает, что в перспективных моделях следует использовать мультимодальные источники данных, включая связь V2X, спутниковые снимки и ленты социальных сетей, чтобы обеспечить более полное понимание ДТП. Для улучшения понимания причинно-следственных связей между переменными и результатами аварий следует использовать методы причинно-следственного машинного обучения, такие как двойное робастное обучение. Создание систем поддержки принятия решений в режиме реального времени с использованием прогностических моделей поможет операторам дорожного движения и водителям принимать обоснованные решения для снижения риска аварий.

Заключение

Моделирование дорожно-транспортных происшествий значительно продвинулось благодаря включению разнообразных источников данных и сложных методов машинного обучения. Графовые нейронные сети, модели на основе внимания и гибридные методы продемонстрировали потенциал в улавливании пространственно-временной неоднородности и повышении точности прогнозирования. Будущие исследования должны сосредоточиться на использовании мультимодальных данных, причинно-следственного машинного обучения и систем поддержки принятия решений в реальном времени для повышения безопасности дорожного движения [1, 3].

Список источников

1. Uthaib M.A., Tyutyunnik V.M. Pattern recognition of the state registration plate of a vehicle // Мир науки без границ: материалы XI Всерос. науч.-практ. конф. молодых учёных. Тамбов: издат. Центр ФГБОУ ВО «ТГТУ», 2024. С. 285–287.
2. Удаиб М.А. Современные методы и информационные системы фиксирования, прогнозирования и предотвращения дорожно-транспортных происшествий // Информационные процессы, системы и технологии. 2024. Т.5. №2. С. 14–22. DOI: 10.52529/27821617_2024_5_2_14
3. Тютюнник В.М., Удаиб М.А. Нейросетевые методы и модели прогнозирования дорожно-транспортных происшествий и снижения их рисков // Промышленные АСУ и контроллеры. 2024. №12. С. 47–56. DOI: 10.25791/asu.12.2024.15483
4. Uthaib M.A., Tyutyunnik V.M. Integrating situational factors and heterogeneous data for enhanced traffic accident analysis // Общество. 2025. №1 (36), Ч. 2. С. 15–19.

5. Uthaib M.A., Tyutyunnik V.M. The effects of heterogeneous information in analyzing traffic accidents // Мир науки без границ: сб. материалов 12-й Междунар. науч.-практ. конф. молодых учёных. Тамбов: Издат. центр ФГБОУ ВО «ТГТУ», 2025. С. 41–44.
6. SMA-HYPER: Spatiotemporal Multi-View Fusion Hypergraph Learning for Traffic Accident Prediction / X. Gao [et al.] // Preprint Submitted to Elsevier, 2024.
7. Ghahremannezhad H., Shi H., Liu C. Real-Time Accident Detection in Traffic Surveillance Using Deep Learning. 2022. URL: <https://doi.org/10.48550/arXiv.2208.06461> (дата обращения: 20.02.2026).
8. Graph Neural Networks for Road Safety Modeling: Datasets and Evaluations for Accident Analysis / A. Nippani [et al.] // 2023. URL: [arXiv.org.2311.00164](https://arxiv.org/abs/2311.00164) (дата обращения: 20.02.2026).
9. Interpretable Traffic Accident Prediction: Attention Spatial–Temporal Multi-Graph Traffic Stream Learning Approach / C. Li [et al.] // IEEE Transactions on Intelligent Transportation Systemsю 2024. P. 1–13.
10. Predictive analysis for road accidents using a tree-based and deep learning fusion system / M. Ameksa [et al.] // Journal of Intelligent and Fuzzy Systems. 2023. Vol. 46. P. 2381–2397.
11. AccidentGPT: Accident Analysis and Prevention from V2X Environmental Perception with Multi-modal Large Model / L. Wang [et al.] // 2023. Vol. abs/2312.13156.
12. Exploring the spatiotemporal heterogeneity of freeway secondary crashes using GTWR model / H. Liu [et al.] // Journal of Transportation Safety & Security. 2023. P. 1–24.
13. Jiang J., Miao Y., Wu D. Machine Learning-based Prediction Analysis of Potential Factors in Traffic Accidents // Applied and Computational Engineering. EWA Publishing. 2024. Vol. 99. № 1. P. 112–120.
14. Sukonna R.T., Swapnil S.I. A Bi-level Framework for Traffic Accident Duration Prediction: Leveraging Weather and Road Condition Data within a Practical Optimum Pipeline // URL: [arXiv.org.2311.00634](https://arxiv.org/abs/2311.00634) (дата обращения: 20.02.2026).
15. It Is About Weather: Explainable Machine Learning for Traffic Accident Understanding. / S. Soedirman [et al.] // 2023. P. 2689–2694.
16. Exploring spatial heterogeneity in factors associated with injury severity in speeding-related crashes: An integrated machine learning and spatial modeling approach / Z. Zhang [et al.] // Accident Analysis & Prevention. Elsevier BV, 2024. Vol. 206. P. 107697.
17. Prediction of Accident Risk Levels in Traffic Accidents Using Deep Learning and Radial Basis Function Neural Networks Applied to a Dataset with Information on Driving Events / C. Arciniegas-Ayala [et al.] // Applied Sciences. Multidisciplinary Digital Publishing Institute, 2024. Vol. 14. № 14. P. 6248.
18. Sorum N.G., Pal D. Identification of the best machine learning model for the prediction of driver injury severity // International Journal of Injury Control and Safety Promotion. 2024. P. 1–16.
19. Mehdi M. Machine learning and multisource data analysis approach towards traffic accident risk prediction // Scientific Publishing Center InterConf. 2024. No. 50 (221). P. 401–406.
20. Development and Application of Highway Traffic Congestion and Accident Risk Early / B. Xie [et al.] // Warning Model. 2024. P. 1519–1523.
21. Nayak A., Goyal K. Traffic modeling and accidental data analysis using GIS // A Review. 2024.
22. Machine Learning Applications in Traffic Safety / S. Priyanka [et al.]. // Assessing Accident Severity Automatically. 2023. P. 1197–1203.
23. Exploring the spatiotemporal heterogeneity of freeway secondary crashes using GTWR model / H. Liu [et al.] // Journal of Transportation Safety & Security. 2023. P. 1–24.
24. Benfaress I., Bouhoute A., Zinedine A. Enhancing Traffic Accident Severity Prediction Using ResNet and SHAP for Interpretability // AI. Multidisciplinary Digital Publishing Institute, 2024. Vol. 5. No.4. P. 2568–2585.

25. Kashifi M.T. Robust spatiotemporal crash risk prediction with gated recurrent convolution network and interpretable insights from SHapley additive explanations // *Engineering Applications of Artificial Intelligence*. 2024.

References

1. Uthaib M.A., Tyutyunnik V.M. Pattern recognition of the state registration plate of a vehicle // *Mir nauki bez granic: materialy XI Vseros. nauch.-prakt. konf. molodyh uchyonyh*. Tambov: izdat. Centr FGBOU VO «TGTU», 2024. S. 285–287.
2. Udaib M.A. Sovremennye metody i informacionnye sistemy fiksirovaniya, prognozirovaniya i predotvrashcheniya dorozhno-transportnyh proisshestvij // *Informacionnye processy, sistemy i tekhnologii*. 2024. T.5. №2. S. 14–22. DOI: 10.52529/27821617_2024_5_2_14
3. Tyutyunnik V.M., Udaib M.A. Nejrosetevye metody i modeli prognozirovaniya dorozhno-transportnyh proisshestvij i snizheniya ih riskov // *Promyshlennye ASU i kontroly*. 2024. №12. S. 47–56. DOI: 10.25791/asu.12.2024.15483
4. Uthaib M.A., Tyutyunnik V.M. Integrating situational factors and heterogeneous data for enhanced traffic accident analysis // *Obshchestvo*. 2025. №1 (36), Ch. 2. S. 15–19.
5. Uthaib M.A., Tyutyunnik V.M. The effects of heterogeneous information in analyzing traffic accidents // *Mir nauki bez granic: sb. materialov 12-j Mezhdunar. nauch.-prakt. konf. molodyh uchyonyh*. Tambov: Izdat. centr FGBOU VO «TGTU», 2025. S. 41–44.
6. SMA-HYPER: Spatiotemporal Multi-View Fusion Hypergraph Learning for Traffic Accident Prediction / X. Gao [et al.] // Preprint Submitted to Elsevier, 2024.
7. Ghahremannezhad H., Shi H., Liu C. Real-Time Accident Detection in Traffic Surveillance Using Deep Learning. 2022. URL: <https://doi.org/10.48550/arXiv.2208.06461> (data obrashcheniya: 20.02.2026).
8. Graph Neural Networks for Road Safety Modeling: Datasets and Evaluations for Accident Analysis / A. Nippani [et al.] // 2023. URL: [arXiv.org.2311.00164](https://arxiv.org/abs/2311.00164) (data obrashcheniya: 20.02.2026).
9. Interpretable Traffic Accident Prediction: Attention Spatial–Temporal Multi-Graph Traffic Stream Learning Approach / C. Li [et al.] // *IEEE Transactions on Intelligent Transportation Systems* 2024. P. 1–13.
10. Predictive analysis for road accidents using a tree-based and deep learning fusion system / M. Ameksa [et al.] // *Journal of Intelligent and Fuzzy Systems*. 2023. Vol. 46. P. 2381–2397.
11. AccidentGPT: Accident Analysis and Prevention from V2X Environmental Perception with Multi-modal Large Model / L. Wang [et al.] // 2023. Vol. abs/2312.13156.
12. Exploring the spatiotemporal heterogeneity of freeway secondary crashes using GTWR model / H. Liu [et al.] // *Journal of Transportation Safety & Security*. 2023. P. 1–24.
13. Jiang J., Miao Y., Wu D. Machine Learning-based Prediction Analysis of Potential Factors in Traffic Accidents // *Applied and Computational Engineering*. EWA Publishing. 2024. Vol. 99. № 1. P. 112–120.
14. Sukonna R.T., Swapnil S.I. A Bi-level Framework for Traffic Accident Duration Prediction: Leveraging Weather and Road Condition Data within a Practical Optimum Pipeline // URL: [arXiv.org.2311.00634](https://arxiv.org/abs/2311.00634) (data obrashcheniya: 20.02.2026).
15. It Is About Weather: Explainable Machine Learning for Traffic Accident Understanding. / S. Soedirman [et al.] // 2023. P. 2689–2694.
16. Exploring spatial heterogeneity in factors associated with injury severity in speeding-related crashes: An integrated machine learning and spatial modeling approach / Z. Zhang [et al.] // *Accident Analysis & Prevention*. Elsevier BV, 2024. Vol. 206. P. 107697.
17. Prediction of Accident Risk Levels in Traffic Accidents Using Deep Learning and Radial Basis Function Neural Networks Applied to a Dataset with Information on Driving Events / C. Arciniegas-Ayala [et al.] // *Applied Sciences*. Multidisciplinary Digital Publishing Institute, 2024. Vol. 14. № 14. P. 6248.

18. Sorum N.G., Pal D. Identification of the best machine learning model for the prediction of driver injury severity // *International Journal of Injury Control and Safety Promotion*. 2024. P. 1–16.
19. Mehdi M. Machine learning and multisource data analysis approach towards traffic accident risk prediction // *Scientific Publishing Center InterConf*. 2024. No. 50 (221). P. 401–406.
20. Development and Application of Highway Traffic Congestion and Accident Risk Early / B. Xie [et al.] // *Warning Model*. 2024. P. 1519–1523.
21. Nayak A., Goyal K. Traffic modeling and accidental data analysis using GIS // *A Review*. 2024.
22. Machine Learning Applications in Traffic Safety / S. Priyanka [et al.]. // *Assessing Accident Severity Automatically*. 2023. P. 1197–1203.
23. Exploring the spatiotemporal heterogeneity of freeway secondary crashes using GTWR model / H. Liu [et al.]. // *Journal of Transportation Safety & Security*. 2023. P. 1–24.
24. Benfaress I., Bouhoute A., Zinedine A. Enhancing Traffic Accident Severity Prediction Using ResNet and SHAP for Interpretability // *AI. Multidisciplinary Digital Publishing Institute*, 2024. Vol. 5. No.4. P. 2568–2585.
25. Kashifi M.T. Robust spatiotemporal crash risk prediction with gated recurrent convolution network and interpretable insights from SHapley additive explanations // *Engineering Applications of Artificial Intelligence*. 2024.

Информация о статье:

Статья поступила в редакцию: 12.01.2026; одобрена после рецензирования: 08.06.2026; принята к публикации: 15.06.2026

Information about the article:

The article was submitted to the editorial office: 12.01.2026; approved after review: 08.06.2026; accepted for publication: 15.06.2026

Информация об авторах:

Тютюнник Вячеслав Михайлович, профессор кафедры радиоэлектронных и микропроцессорных систем Тамбовского государственного технического университета (392000, г. Тамбов, ул. Советская, д. 106/5), доктор технических наук, профессор, e-mail: vmtyutyunnik@gmail.com, SPIN-код: 1442-1686, ORCID: 0000-0003-2099-5730

Удаиб Масар Абед, аспирант Тамбовского государственного технического университета (392000, г. Тамбов, ул. Советская, д. 106/5), e-mail: masar.uthaib2018@gmail.com, SPIN- код: 6875-8867

Information about the authors:

Vyacheslav Mikhailovich Tyutyunnik, Professor of the Department of Radio-Electronic and Microprocessor Systems at Tambov State Technical University (106/5 Sovetskaya Street, Tambov, 392000), Doctor of Technical Sciences, Professor, e-mail: vmtyutyunnik@gmail.com, SPIN-code: 1442-1686, ORCID: 0000-0003-2099-5730

Udaib Masar Abed, Postgraduate Student at Tambov State Technical University (106/5 Sovetskaya Street, Tambov, 392000), e-mail: masar.uthaib2018@gmail.com, SPIN-code: 6875-8867