

**Р. Н. Минниханов, А. С. Катасёв, Д. В. Катасёва,
В. Скибин**

НЕЙРОСЕТЕВЫЕ СВЕРТОЧНЫЕ МОДЕЛИ ОБНАРУЖЕНИЯ И РАСПОЗНАВАНИЯ СИГНАЛОВ СВЕТОФОРА

Ключевые слова: сигналы светофора, сверточные нейронные сети, распознавание объектов, модель Faster R-CNN, модель YOLOv8n.

Статья посвящена построению и исследованию сверточных нейросетевых моделей для обнаружения и распознавания сигналов светофора. Для решения этих задач используются различные методы и алгоритмы, такие как цветовые фильтры, сопоставление адаптивных шаблонов, контурный анализ, методы машинного обучения, алгоритмы компьютерного зрения. Многие технологические компании создают системы для распознавания сигналов светофора и элементов дорожной инфраструктуры. В данной работе для распознавания сигналов светофора проведен сравнительный анализ двух архитектур сверточных нейронных сетей: YOLOv8n и Faster R-CNN. Выбор этих архитектур обусловлен их высокой эффективностью в решении задач обнаружения и распознавания объектов на изображениях. Решение поставленных задач потребовало реализации следующих этапов: сбора и подготовки исходного набора данных для моделирования, выбора необходимого инструментария для построения моделей, выбора архитектуры и обучения сверточных нейронных сетей, а также проведения экспериментальных исследований на базе построенных моделей. В качестве исходного набора данных выбран набор LISA, содержащий большое количество различных обучающих примеров в виде изображений размера 1280×960. Исходные данные были разделены на обучающую, валидационную (для контроля переобучения) и тестовую (для оценки адекватности моделей) выборки в пропорциях 80%, 10% и 10%. Ночные и дневные снимки были равномерно распределены между всеми выборками. Кроме того, для аугментации исходных данных применялись геометрические преобразования и изменения изображения на уровне пикселей: поворот на небольшой угол, обрезка, масштабирование, изменение яркости и насыщенности изображения. Итоговое количество изображений составило 43107, включая 34485 примеров для обучения моделей, 4311 – для их валидации и 4311 – для тестирования. В качестве языка программирования выбран Python. При обучении значение функции потерь для сети Faster R-CNN составило 0,11, а для YOLOv8n – 0,25. При этом обе модели показали приемлемые результаты при распознавании как ближних, так и дальних объектов. При этом наиболее эффективной оказалась модель YOLOv8n. Она незначительно уступает в точности, однако примерно в 5,5 раз быстрее производит распознавание сигналов светофора по сравнению с Faster R-CNN. Это позволяет использовать ее в режиме реального времени, например, в системах автономного управления транспортными средствами.

**R. N. Minnikhanov, A. S. Katasev, D. V. Kataseva,
V. Skibin**

NEURAL NETWORK CONVOLUTIONAL MODELS FOR TRAFFIC LIGHT DETECTION AND RECOGNITION

Keywords: traffic light signals, convolutional neural networks, object recognition, Faster R-CNN model, YOLOv8n model.

The article is devoted to the construction and study of convolutional neural network models for detection and recognition of traffic light signals. To solve these problems, various methods and algorithms are used, such as color filters, adaptive pattern matching, contour analysis, machine learning methods, computer vision algorithms. Many technology companies create systems for recognizing traffic light signals and road infrastructure elements. In this paper, a comparative analysis of two architectures of convolutional neural networks was carried out for recognizing traffic light signals: YOLOv8n and Faster R-CNN. The choice of these architectures is due to their high efficiency in solving problems of detecting and recognizing objects in images. The solution of the tasks required the implementation of the following stages: collecting and preparing the initial dataset for modeling, selecting the necessary tools for building models, selecting the architecture and training convolutional neural networks, as well as conducting experimental studies based on the constructed models. The LISA set was selected as the initial dataset, containing a large number of different training examples in the form of 1280 × 960 images. The source data was divided into training, validation (to control overfitting) and test (to assess the adequacy of the models) samples in the proportions of 80%, 10% and 10%. Night and daytime images were evenly distributed between all samples. In addition, geometric transformations and image changes at the pixel level were used to augment the source data: rotation by a small angle, cropping, scaling, changing the brightness and saturation of the image. The final number of images was 43107, including 34485 examples for training the models, 4311 for their validation and 4311 for testing. Python was chosen as the programming language. During training, the loss function value for the Faster R-CNN network was 0.11, and for YOLOv8n it was 0.25. At the same time, both models showed acceptable results in recognizing both near and far objects. At the same time, the YOLOv8n model was the most effective. It is slightly inferior in accuracy, but it recognizes traffic lights approximately 5.5 times faster than Faster R-CNN. This allows it to be used in real-time, for example, in autonomous vehicle control systems.

Введение

В современном мире стремительными темпами развиваются интеллектуальные транспортные системы [1-3]. Разработка таких систем является трудоемкой задачей, включающей в себя, в частности, распознавание дорожных знаков [4, 5], дорожной разметки [6, 7] и сигналов светофора [8] в режиме реального времени для принятия решений [9].

Распознавание сигналов светофора является одним из наиболее важных функционалов в интеллектуальных системах для беспилотных автомобилей [10], что позволяет повышать безопасность водителей и своевременно предотвращать дорожно-транспортные происшествия. Одним из преимуществ беспилотных автомобилей является то, что, в отличие от людей, они не подвержены усталости, стрессу и эмоциям [11]. Автономные системы можно использовать также, когда водитель сам управляет транспортным средством, а в чрезвычайных ситуациях система берет управление на себя, например, когда водитель теряет сознание. Однако для этого необходимо собирать дополнительные сведения о состоянии человека (пульс, температура тела и др.) с использованием различных датчиков.

Кроме этого, решение данной задачи можно интегрировать в умные города [12] и технологию Интернета вещей [13]. Анализируя сигналы светофора с камер наблюдений, можно оптимизировать движение транспортного потока, что способствует уменьшению пробок и разгрузке транспортных путей. Для оптимизации потока автотранспортных средств необходимо скорректировать время отображения красного и зеленого сигналов светофора. Следовательно, задача обнаружения и распознавания сигналов светофора является актуальной.

Обзор подходов и систем для распознавания сигналов светофора

Для распознавания сигналов светофора используются различные алгоритмы и методы [10, 14-16]: цветовые фильтры, сопоставление адаптивных шаблонов, контурный анализ, методы машинного обучения, алгоритмы компьютерного зрения и т.д. Так, например, в работе [17] описан подход на основе объединения нисходящих и восходящих процессов марковской цепи Монте-Карло. Алгоритм вычисляет края светофора на цветном изображении, представляя светофор в виде совокупности примитивных геометрических фигур: прямоугольников и кругов. Затем найденные границы используются для выделения шаблонов при фильтрации для нахождения горячих точек на изображении. Для быстрого определения горячих точек используется метод обнаружения сигнала минимального риска. После этого из изображения выделяются области со светофорами и марковская цепь Монте-Карло производит распознавание сигнала светофора. Однако, данный подход показывает низкие результаты для светофора с дополнительными секциями.

В [18] используется функция Хаара для классификации сигналов светофора. На первом шаге используется $YCbCr$ представление изображения с видекамеры для детектора потенциальных свето-

форов: если $Cr < 122$ и $Cb > 120$, то это зеленый сигнал; если $Cr > 145$, то это красный сигнал. Для получения корректного результата используются CMOS-сенсоры с высоким динамическим диапазоном. Затем изображение размывается и сегментируется при помощи анализа связанных компонентов. На втором шаге используется фильтр формы, который удаляет шумы на изображении по определенным критериям. На последнем шаге применяется алгоритм адаптивной многоклассовой классификации, использующий функцию Хаара. Недостатком является то, что данный метод ошибочно принимает сигнал автомобильной фары за сигнал светофора в ночное время суток.

В исследовании [19] распознавание осуществляется при помощи адаптивных шаблонов. Вначале алгоритм в оттенках серого анализирует изображение, где обнаружение точечного света происходит при помощи морфологического оператора «цилиндр», позволяющего определить яркие области на изображении. На данном этапе могут присутствовать ложные предсказания, которые будут отсеяны позднее. Далее сопоставляются заранее подготовленные адаптивные геометрические и алгоритмические шаблоны с полученными на предыдущем шаге областями с потенциальными светофорами. После этого происходит простая фильтрация, где определяется цвет сигнала светофора. Из недостатков данного подхода можно отметить то, что он плохо распознает дальние светофоры.

В [20] используется HSV-преобразование и контурный анализ. На первом этапе увеличивается яркость изображения. На втором этапе изображение сегментируется и применяется морфологическая обработка (коррозия и расширение изображения) для извлечения регионов интереса и очистки от шума. На последнем этапе посредством оператора Кэнни определяется контур объекта и извлекается светофор. Данный метод плохо распознает сигналы светофора в условиях недостаточной освещенности.

В работе [21] применяется двоично-семантическая сегментация для поиска регионов интереса. Для семантической сегментации используется сверточная нейронная сеть (СНС) на основе E-Net, определяющая интересующие области за один проход, что позволяет использовать меньше памяти. Для классификации используется специальная СНС с тремя фильтрами и несколькими полностью связными слоями. Модель показывает хорошие результаты при распознавании сигналов светофора и снижает технические требования к оборудованию.

В настоящее время многие компании создают собственные системы для распознавания сигналов светофора и элементов дорожной инфраструктуры. Примерами таких систем являются Traffic Light and Stop Sign Control и Traffic Sign Recognition.

Traffic Light and Stop Sign Control – система обнаружения и реагирования на сигналы светофора и стоп-знаки, созданная компанией Tesla. Ее можно включить при круиз-контроле или при полностью автономном управлении автомобилем. Принцип работы системы заключается в том, что транспортное средство замедляется или полностью останавли-

вается перед светофором или стоп-линией, после чего водитель должен подтвердить дальнейшее движение, нажав на рычаг привода. Для принятия решения анализируется видеопоток с нескольких камер, что позволяет получить актуальную и полную картину дорожной обстановки.

Система Traffic Sign Recognition впервые появилась в 2008 году для автомобилей модели Opel Insignia. Позже эта система использовалась в BMW 7 серии и Mercedes-Benz. Технология позволяет определять знаки дорожного движения (ограничение скорости, поворот налево, парковка запрещена). Если обнаружен знак ограничения скорости, то на приборной панели транспортного средства будет присутствовать информация о максимально допустимой скорости до тех пор, пока не появится другое ограничение скорости.

В данной работе проведено сравнение двух архитектур: YOLOv8n [22, 23] и Faster R-CNN [24, 25]. Выбранные модели, как правило, показывают высокие результаты в решении задач обнаружения и распознавания объектов [26-29].

Сбор и подготовка данных для нейросетевого моделирования

Для распознавания сигналов светофора в сети Интернет доступны следующие наборы изображений [10]: LaRa, LISA, BSTLD, BDD100K и DTLД. Основные характеристики этих наборов данных представлены в таблице 1.

Таблица 1 – Основные характеристики рассмотренных наборов данных

Table 1 – Main characteristics of the considered datasets

Набор данных	Число изображений	Разрешение изображения	Число объектов	Число классов
LaRa	11179	640×480	9168	4
LISA	43007	1280×960	113888	7
BSTLD	13427	1280×720	24242	14
BDD100K	100000	1280×720	н/д	10
DTLD	40979	2048×1024	292245	620

В качестве основного набора данных в работе выбран набор LISA, поскольку размер изображений и их количество в данном наборе оптимально. Кроме того, он содержит разнообразные сцены, в частности, различные погодные условия (солнце, дождь), различные времена суток (день, ночь) и объекты, похожие на сигналы светофора (фары автомобилей). Этого достаточно для репрезентативности выборок и построения адекватных нейросетевых моделей. В набор были также добавлены собственные изображения в количестве 100 штук.

На вход нейронным сетям подавались изображения размера 1280×960. Таблица исходных данных содержала 10 столбцов, на основе которых определяется местоположение и сигнал светофора:

- filename – имя файла;

- annotation tag – класс объекта («go», «go left», «go forward», «warning», «waning left», «stop», «stop left»);

- upper left corner X – координата X верхнего левого угла ограничивающей рамки светофора;

- upper left corner Y – координата Y верхнего левого угла ограничивающей рамки светофора;

- lower right corner X – координата X правого нижнего угла ограничивающей рамки светофора;

- lower right corner Y – координата Y правого нижнего угла ограничивающей рамки светофора;

- origin file – относительный путь к видеофайлу;

- origin frame number – номер кадра на видео;

- origin track – путь к видеофайлу;

- origin track frame number – номер кадра на видеопоследовательности.

Для обработки и анализа файлов был написан скрипт на языке Python. Из данных были удалены избыточные и ненужные столбцы исходной таблицы: origin file, origin track, origin track frame number и origin frame number.

При обработке данных было произведено изменение наименований и сокращение количества классов объектов. Классы «go», «go left», «go forward» были заменены классом «green» (номер класса 1). Классы «warning», «waning left» были заменены классом «yellow» (номер класса 2). Классы «stop», «stop left» – классом «red» (номер класса 3).

Исходные данные были разделены на обучающую, валидационную (для контроля переобучения) и тестовую (для оценки адекватности построенной модели) выборки в пропорциях 80%, 10% и 10%. Ночные и дневные снимки были равномерно распределены между выборками.

При обработке данных также был изменен формат для определения местоположения светофора на изображении: вместо координат углов ограничивающей рамки использовались ее центр, ширина и высота, нормализованные на отрезке [0; 1]. Аннотирование сигналов светофора происходило на платформе Roboflow, предоставляющей удобный пользовательский интерфейс для работы с наборами изображений [30]. Итоговое количество изображений составило 43107, где обучающая выборка содержала 34485, валидационная – 4311 и тестовая – 4311 примеров.

В работе для аугментации данных [31, 32] применялись геометрические преобразования и изменения изображения на уровне пикселей [33]: поворот на небольшой угол, обрезка, масштабирование, изменение яркости и насыщенности изображения, что повысило точность распознавания изображений.

Построение нейросетевых моделей

В качестве основного языка программирования выбран Python. Также выбраны следующие библиотеки и фреймворки [34]: PyTorch, NumPy, Pandas, Scikit-learn, OpenCV, Pillow, Matplotlib и Tkinter.

Для работы с глубокими сетями выбран фреймворк с открытым исходным кодом PyTorch, созданный на базе библиотеки Torch для языка программирования Lua, использующийся для компьютерного зрения, обработки естественного языка и обуче-

ния с подкреплением в крупных технологических компаниях. PyTorch позволяет производить тензорные вычисления на графическом ускорителе с использованием технологии CUDA от Nvidia.

В сравнении с TensorFlow, PyTorch поддерживает динамические вычислительные узлы, имеет хорошую документацию и предоставляет удобный открытый интерфейс для разработчиков.

В работе рассматривались две архитектуры сверточных нейронных сетей [35]: Faster R-CNN и YOLOv8n. Для повышения точности моделей при их обучении использовалась пакетная нормализация [36, 37]. Суть метода заключается в том, чтобы нормализовать данные (нулевое математическое ожидание и единичная дисперсия) и подать их на вход при обучении нейронной сети [38]. Обычно размер пакета равен некоторой степени числа 2.

При обучении Faster R-CNN размер пакета составлял 8, а для YOLOv8n – 32, так как модель является более легковесной. Количество эпох для Faster R-CNN – 5, для YOLOv8n – 100. Время, затраченное на обучение для Faster R-CNN, составило 5 часов, для YOLOv8n – 3,5 часа.

На рисунках 1 и 2 показаны графики функций потерь на обучающей (train) и валидационной (validation) выборках данных для построенных моделей.




Рис. 1 – Графики функций потерь при обучении сети Faster R-CNN

Fig. 1 – Graphs of the loss functions during training of the Faster R-CNN network




Рис. 2 – Графики функций потерь при обучении сети YOLOv8n

Fig. 2 – Graphs of loss functions during training of YOLOv8n network

Из рисунков видно, что для выбранных нейронных сетей установлено оптимальное количество эпох для обучения, так как графики функций потерь вышли на плато. Кроме того, видно, что модели не переобучились [39, 40]. На последней эпохе на обучающей выборке значение функции потерь для сети Faster R-CNN составило 0,11, а для YOLOv8n – 0,25.

Оценка адекватности построенных нейросетевых моделей

Для оценки адекватности работы моделей [41, 42] использовалась тестовая выборка, состоящая из 4311 изображений. На рисунках 3 и 4 представлены результаты тестирования моделей.



Рис. 3 – Пример распознавания сигналов светофора моделью Faster R-CNN

Fig. 3 – An example of traffic light signal recognition by the Faster R-CNN model



Рис. 4 – Пример распознавания сигналов светофора моделью YOLOv8n

Fig. 4 – An example of traffic light signal recognition by the YOLOv8n model

Из рисунков видно, что обе построенные модели корректно распознают сигналы светофора, однако модель Faster R-CNN делает более точные расчеты. Модели показывают приемлемые результаты как при распознавании ближних объектов, так и объектов, расположенных вдали.

В таблице 2 представлены рассчитанные значения метрик точности, полноты и F1-меры [43] для модели Faster R-CNN.

Таблица 2 – Значения метрик качества классификации для модели Faster R-CNN

Table 2 – Classification quality metrics values for Faster R-CNN model

Сигналы \ Метрики	Точность	Полнота	F1-мера
Красный сигнал	0,936	0,938	0,937
Желтый сигнал	0,885	0,871	0,878
Зеленый сигнал	0,914	0,899	0,906

Значения соответствующих метрик для модели YO-LOv8n представлены в таблице 3.

Таблица 3 – Значения метрик качества классификации для модели YOLOv8n

Table 3 – Classification quality metrics values for the YOLOv8n model

Сигналы \ Метрики	Точность	Полнота	F1-мера
Красный сигнал	0,937	0,921	0,929
Желтый сигнал	0,878	0,884	0,881
Зеленый сигнал	0,907	0,903	0,905

Из таблиц видно, что модели хорошо распознают все сигналы светофора. Значение усредненной по классам метрики F1-мера для модели Faster R-CNN составляет 0,907, а для модели YOLOv8n – 0,905. Следовательно, модели являются адекватными.

Модель Faster RCNN имеет метрику mAP50 = 0,966, а YOLOv8n – 0,955. Следовательно, модель Faster RCNN более точно распознает сигналы светофора. Размер модели Faster R-CNN составляет примерно 158 Мб, а YOLOv8n – 5,93 Мб.

При условии, что для распознавания используется графический ускоритель RTX 2060 Super, если на вход моделям подавать видеопоток, то модель Faster R-CNN будет иметь скорость распознавания 10 кадров в секунду, а модель YOLOv8n – 55.

Анализируя характеристики и значения метрик для построенных моделей, наиболее эффективной является модель YOLOv8n. Она незначительно уступает в точности, однако в 5,5 раз быстрее производит распознавание. При этом модель в 27 раз меньше по объему, чем Faster R-CNN, однако для обеих моделей нужны производительные графические чипы для быстрого распознавания.

В целом при построении моделей СНС следует учитывать, что изображения, имеющие большой размер, сильно нагружают графический процессор. При этом изображения меньших размеров уменьшают точность распознавания. Если СНС используется в режиме реального времени, то необходимо уменьшать размер изображения, подаваемого на ее вход, что повысит скорость работы, но незначительно снизит точность распознавания.

Заключение

Проведенное исследование показало, что обе построенные модели являются адекватными, однако различаются по своим характеристикам. Модель YOLOv8n, несмотря на то, что менее точна по срав-

нению с моделью Faster R-CNN, однако превосходит ее по другим показателям: по скорости работы и по объему. Поэтому в качестве наиболее эффективной модели целесообразно использовать именно эту нейронную сеть. В дальнейшем модель можно обобщить на случай распознавания большего количества объектов дорожной инфраструктуры [44] и использовать, например, в составе мобильного приложения или интеллектуальной системы поддержки принятия решений для оперативного оповещения водителя о ситуации на дороге.

Литература

1. V.N. Voronin, A.A. Bimbinov, A.L. Blagodir, *Journal of Siberian Federal University. Humanities and Social Sciences*, **14**, 5, 611-620 (2021).
2. С.В. Плетнев, А.В. Ференец, *Вестник НЦБЖД*, 3 (29), 47-49 (2016).
3. М.Е. Елисеев, Е.Д. Галкина, Л.Н. Мазунова, *Труды НГТУ им. П.Е. Алексеева*, 1 (132), 14-23 (2021).
4. А.И. Сабиров, А.С. Катасёв, М.В. Дагаева, *Компьютерные исследования и моделирование*, **13**, 2, 429-435 (2021).
5. С.Ю. Пчелинцев, О.А. Ковалева, *Информационные технологии*, **28**, 8, 424-428 (2022).
6. М.В. Мухортов, В.В. Евграфов, *Труды НАМИ*, 1 (276), 45-54 (2019).
7. М.П. Шлеймович, М.В. Дагаева, А.С. Катасёв, С.А. Ляшева, М.В. Медведев, *Компьютерные исследования и моделирование*, **10**, 3, 369-376 (2018).
8. О.А. Пырнова, Р.С. Зарипова, *International Journal of Advanced Studies*, **12**, 3-2, 46-51 (2022).
9. С.В. Воронов, Р.Н. Мухометзянов, *Автоматизация процессов управления*, 2 (52), 105-111 (2018).
10. Р.М. Шакирзянов, *Вестник Воронежского государственного университета*, **16**, 6, 25-33 (2020).
11. А.М. Ахметвалеев, А.С. Катасёв, *Компьютерные исследования и моделирование*, **10**, 3, 285-293 (2018).
12. А.И. Bogomolov, V.P. Nevezhin, *Modern Information Technologies and IT-Education*, **18**, 4, 846-854 (2022).
13. U.A. Vishniakou, A.H. Al-Masri, *System Analysis and Applied Information Science*, 2, 11-16 (2020).
14. А.С. Катасёв, Ч.Ф. Ахатова, *Программные продукты и системы*, 3, 6-12 (2011).
15. И.В. Бадыков, И.Ю. Мышкина, Л.Ю. Грудцына, *Научно-технический вестник Поволжья*, 5, 12-14 (2019).
16. А.О. Барина, Д.В. Катасёва, А.С. Катасёв, *Вестник Технологического университета*, **23**, 10, 75-78 (2020).
17. Z. Tu, *International Archives of ISPRS*, **33**, 2, 294-298 (2000).
18. H.K. Kim, *International Journal of Electrical and Computer Engineering*, **5**, 11, 1429-1432 (2011).
19. R. Charette, F. Nashashibi, *Intelligent Robots and Systems*, 5, 333-338 (2009).
20. U.R. Xamdamov, F.A. Muradov, M.A. Umarov, I.M. Boynazarov, *Computational and Applied Mathematics Problems*, 3(41), 156-172 (2022).
21. H.K. Kim, *Sensors*, **19**, 7, 170-182 (2019).
22. Q. Liu, W. Huang, X. Duan, J. Wei, T. Hu, J. Yu, J. Huang, *Electronics*, **12**, 18, 3892 (2023).
23. А.О. Евсеева, А.С. Катасёв, Д.В. Катасёва, *Информация и безопасность*, **19**, 4, 535-538 (2016).
24. W. Xichen, P. Fulun, Li. Yexun, Zh. Junju, *Journal of Applied Optics*, **45**, 2, 346-353 (2024).
25. О.А. Пырнова, М.Г. Кузнецов, Д.П. Никоноров, *Научно-технический вестник Поволжья*, 12, 369-372 (2023).
26. Н.Н. Зиятдинов, Л.М. Дмитриева, А.Е. Сержкина, М.Е. Дмитриев, *Вестник Технологического университета*, **18**, 2, 357-361 (2015).

27. Ю.Н. Воробьева, Д.В. Катасёва, А.С. Катасёв, А.П. Кирпичников, *Вестник Технологического университета*, **21**, 2, 94-98 (2018).
28. Д.В. Катасёва, А.О. Барина, *Вестник Технологического университета*, **25**, 2, 67-70 (2022).
29. С.В. Новикова, Р.И. Ибят, А.А. Валиев, Э.Ш. Кремлева, *Математические методы в технике и технологиях - ММТТ*, **6** (65), 128-131 (2014).
30. Q. Chen, I.E. Grossmann, N.N. Ziyatdinov, I.I. Emel'yanov, *Computers & Chemical Engineering*, **142**, 107042 (2020).
31. А.С. Катасёв, Д.В. Катасёва, А.П. Кирпичников, Я.Е. Семёнов, *Вестник Технологического университета*, **18**, 15, 217-220 (2015).
32. О.А. Пырнова, Р.С. Зарипова, *Информационные технологии в строительных, социальных и экономических системах*, **2** (20), 101-102 (2020).
33. S. Kumar, T. Arif, G. Ahamad, A.A. Chaudhary, M.A.M. Ali, A. Islam, *Discover Applied Sciences*, **6**, 5, 261-268 (2024).
34. A. Sadli, *International Journal of Management Science and Information Technology*, **2**, 2, 21-31 (2022).
35. А.С. Катасёв, Д.В. Катасёва, А.П. Кирпичников, *Вестник Технологического университета*, **18**, 11, 173-176 (2015).
36. Г.М. Островский, Н.Н. Зиятдинов, Ф.У. Мустафина, *Теоретические основы химической технологии*, **47**, 6, 646-655 (2013).
37. Д.Л. Юнани, М.В. Медведев, А.П. Кирпичников, *Вестник Технологического университета*, **22**, 7, 174-178 (2019).
38. I.I. Ismagilov, S.F. Khasanova, A.S. Katasev, D.V. Kataseva, *Journal of Advanced Research in Dynamical and Control Systems*, **10**, 10 Special Issue, 1723-1728 (2018).
39. G.M. Ostrovsky, N.N. Ziyatdinov, T.V. Lapteva, *Chemical Engineering Science*, **65**, 7, 2373-2381 (2010).
40. Н.Р. Кашапов, А.С. Катасёв, Д.В. Катасёва, *Информация и безопасность*, **19**, 4, 555-558 (2016).
41. А.Р. Абдулхаков, А.С. Катасёв, А.П. Кирпичников, *Вестник Казанского технологического университета*, **17**, 23, 389-392 (2014).
42. С.В. Новикова, *Известия высших учебных заведений. Авиационная техника*, **2**, 101-107 (2016).
43. М.В. Дагаева, Д.В. Катасёва, А.С. Катасёв, А.П. Кирпичников, *Вестник Технологического университета*, **21**, 2, 148-154 (2018).
44. I.I. Ismagilov, A.A. Murtazin, D.V. Kataseva, A.S. Katasev, A.O. Barinova, *Caspian Journal of Environmental Sciences*, **18**, 5, 615-621 (2020).
9. S.V. Voronov, R.N. Mukhometzyanov, *Automation of control processes*, **2** (52), 105-111 (2018).
10. R.M. Shakirzyanov, *Bulletin of the Voronezh State University*, **16**, 6, 25-33 (2020).
11. A.M. Akhmetvaleev, A.S. Katasev, *Computer Research and Modeling*, **10**, 3, 285-293 (2018).
12. A.I. Bogomolov, V.P. Nevezhin, *Modern Information Technologies and IT-Education*, **18**, 4, 846-854 (2022).
13. U.A. Vishniakou, A.H. Al-Masri, *System Analysis and Applied Information Science*, **2**, 11-16 (2020).
14. A.S. Katasev, Ch.F. Akhatova, *Software products and systems*, **3**, 6-12 (2011).
15. I.V. Badykov, I.Yu. Myshkina, L.Yu. Grudtsina, *Scientific and Technical Bulletin of the Volga Region*, **5**, 12-14 (2019).
16. A.O. Barinova, D.V. Kataseva, A.S. Katasev, *Herald of Technological University*, **23**, 10, 75-78 (2020).
17. Z. Tu, *International Archives of ISPRS*, **33**, 2, 294-298 (2000).
18. H.K. Kim, *International Journal of Electrical and Computer Engineering*, **5**, 11, 1429-1432 (2011).
19. R. Charette, F. Nashashibi, *Intelligent Robots and Systems*, **5**, 333-338 (2009).
20. U.R. Xamdamov, F.A. Muradov, M.A. Umarov, I.M. Boynazarov, *Computational and Applied Mathematics Problems*, **3**(41), 156-172 (2022).
21. H.K. Kim, *Sensors*, **19**, 7, 170-182 (2019).
22. Q. Liu, W. Huang, X. Duan, J. Wei, T. Hu, J. Yu, J. Huang, *Electronics*, **12**, 18, 3892 (2023).
23. A.O. Evseeva, A.S. Katasev, D.V. Kataseva, *Information and Security*, **19**, 4, 535-538 (2016).
24. W. Xichen, P. Fulun, Li. Yexun, Zh. Junju, *Journal of Applied Optics*, **45**, 2, 346-353 (2024).
25. O.A. Pynova, M.G. Kuznetsov, D.P. Nikonorov, *Scientific and Technical Bulletin of the Volga Region*, **12**, 369-372 (2023).
26. N.N. Ziyatdinov, L.M. Dmitrieva, A.E. Serezhkina, M.E. Dmitriev, *Herald of Technological University*, **18**, 2, 357-361 (2015).
27. Yu.N. Vorobyova, D.V. Kataseva, A.S. Katasev, A.P. Kirpichnikov, *Herald of Technological University*, **21**, 2, 94-98 (2018).
28. D.V. Kataseva, A.O. Barinova, *Herald of Technological University*, **25**, 2, 67-70 (2022).
29. S.V. Novikova, R.I. Ibyatov, A.A. Valiev, E.Sh. Kremleva, *Mathematical Methods in Engineering and Technology - MMTT*, **6** (65), 128-131 (2014).
30. Q. Chen, I.E. Grossmann, N.N. Ziyatdinov, I.I. Emel'yanov, *Computers & Chemical Engineering*, **142**, 107042 (2020).
31. A.S. Katasev, D.V. Kataseva, A.P. Kirpichnikov, Ya.E. Semenov, *Herald of Technological University*, **18**, 15, 217-220 (2015).
32. О.А. Пырнова, Р.С. Зарипова, *Information technologies in construction, social and economic systems*, **2** (20), 101-102 (2020).
33. S. Kumar, T. Arif, G. Ahamad, A.A. Chaudhary, M.A.M. Ali, A. Islam, *Discover Applied Sciences*, **6**, 5, 261-268 (2024).
34. A. Sadli, *International Journal of Management Science and Information Technology*, **2**, 2, 21-31 (2022).
35. A.S. Katasev, D.V. Kataseva, A.P. Kirpichnikov, *Herald of Technological University*, **18**, 11, 173-176 (2015).
36. G.M. Ostrovsky, N.N. Ziyatdinov, F.U. Mustafina, *Theoretical Foundations of Chemical Technology*, **47**, 6, 646-655 (2013).
37. D.L. Yunani, M.V. Medvedev, A.P. Kirpichnikov, *Herald of Technological University*, **22**, 7, 174-178 (2019).
38. I.I. Ismagilov, S.F. Khasanova, A.S. Katasev, D.V. Kataseva, *Journal of Advanced Research in Dynamical and Control Systems*, **10**, 10, 1723-1728 (2018).

References

1. V.N. Voronin, A.A. Bimbinov, A.L. Blagodir, *Journal of Siberian Federal University. Humanities and Social Sciences*, **14**, 5, 611-620 (2021).
2. S.V. Pletnev, A.V. Ferenets, *Bulletin of the National Central Railways*, **3** (29), 47-49 (2016).
3. M.E. Eliseev, E.D. Galkina, L.N. Mazunov, *Proceedings of NSTU im. R.E. Alekseeva*, **1** (132), 14-23 (2021).
4. A.I. Sabirov, A.S. Katasev, M.V. Dagaeva, *Computer Research and Modeling*, **13**, 2, 429-435 (2021).
5. S.Yu. Pchelintsev, O.A. Kovaleva, *Information Technologies*, **28**, 8, 424-428 (2022).
6. M.V. Mukhortov, V.V. Evgrafov, *Proceedings of NAMI*, **1** (276), 45-54 (2019).
7. M.P. Shleimovich, M.V. Dagaeva, A.S. Katasev, S.A. Lyasheva, M.V. Medvedev, *Computer Research and Modeling*, **10**, 3, 369-376 (2018).
8. О.А. Пырнова, Р.С. Зарипова, *International Journal of Advanced Studies*, **12**, 3-2, 46-51 (2022).

39. G.M. Ostrovsky, N.N. Ziyatdinov, T.V. Lapteva, *Chemical Engineering Science*, **65**, 7, 2373-2381 (2010).
40. N.R. Kashapov, A.S. Katasev, D.V. Kataseva, *Information and Security*, **19**, 4, 555-558 (2016).
41. A.R. Abdulhakov, A.S. Katasev, A.P. Kirpichnikov, *Herald of Kazan Technological University*, **17**, 23, 389-392 (2014).
42. S.V. Novikova, *News of Higher Educational Institutions. Aviation Technology*, **2**, 101-107 (2016).
43. M.V. Dagaeva, D.V. Kataseva, A.S. Katasev, A.P. Kirpichnikov, *Herald of Technological University*, **21**, 2, 148-154 (2018).
44. I.I. Ismagilov, A.A. Murtazin, D.V. Kataseva, A.S. Katasev, A.O. Barinova, *Caspian Journal of Environmental Sciences*, **18**, 5, 615-621 (2020).

© **Р. Н. Минниханов** – д-р. техн. наук, профессор, Президент Академии наук Республики Татарстан, директор ГБУ «Безопасность дорожного движения», Казань, Россия, Priemnaya.Minnihanov@tatar.ru; **А. С. Катасёв** – д-р техн. наук, профессор кафедры Систем информационной безопасности (СИБ), Казанский национальный исследовательский технический университет имени А.Н. Туполева (КНИТУ им. А.Н. Туполева), профессор кафедры Цифровых систем и моделей, Казанский государственный энергетический университет, ASKatasev@kai.ru; **Д. В. Катасёва** – канд. техн. наук, доцент кафедры СИБ, КНИТУ им. А.Н. Туполева, dvkataseva@kai.ru; **В. Скибин** – магистрант кафедры СИБ, КНИТУ им. А.Н. Туполева, vladskibin@bk.ru.

© **R. N. Minnikhanov** – Doctor of Sciences (Technical Sci.), Professor, President of Tatarstan Academy of Sciences, Director of the SBI Road Safety, Kazan, Russia, Priemnaya.Minnihanov@tatar.ru; **A. S. Katasev** – Doctor of Sciences (Technical Sci.), Professor of Information Security Systems (ISS) department, Kazan National Research Technical University named after A.N. Tupolev (KNRTU named after A.N. Tupolev), Professor of Digital Systems and Models department, Kazan State Energy University, ASKatasev@kai.ru; **D. V. Kataseva** – PhD (Technical Sci.), Associate Professor of the ISS department, KNRTU named after A.N. Tupolev, dvkataseva@kai.ru; **V. Skibin** – Master-student of the ISS department, KNRTU named after A.N. Tupolev, vladskibin@bk.ru.