

Научная статья  
УДК 004.932.2  
DOI: 10.31857/S0869769824020033  
EDN: ldnkmo

## Разработка метода детектирования объектов транспортных потоков по спутниковым фотоснимкам сверхвысокого разрешения

И. Н. Пугачев<sup>✉</sup>, В. С. Тормозов

*Игорь Николаевич Пугачев*

доктор технических наук, доцент  
Хабаровский федеральный исследовательский центр ДВО РАН, Хабаровск, Россия  
ipugachev64@mail.ru  
<https://orcid.org/0000-0003-0345-4350>

*Владимир Сергеевич Тормозов*

кандидат технических наук, доцент  
Тихоокеанский государственный университет, Хабаровск, Россия  
007465@pnu.edu.ru  
<https://orcid.org/0000-0002-5628-858X>

**Аннотация.** Описывается набор алгоритмов, использующихся для распознавания объектов на спутниковых фотографиях высокого качества. Этот метод обладает уникальной возможностью обнаруживать объекты, размеры которых на изображениях не превышают нескольких десятков пикселей. На фотографии исследуется каждый отличительный участок изображения, чтобы определить присутствие объекта определенного класса, и рассчитывается вероятность этого присутствия на рассматриваемом участке. По результатам анализа изображения делается вывод о наличии и вероятном местонахождении объекта. Дается также подробное объяснение того, как изучаются и параметризуются алгоритмы, используемые в процессе обнаружения. С учетом результатов исследования можно автоматизировать широкий спектр процессов, например, упростить сбор и анализ данных в многочисленных аналитических системах. Метод обладает огромным потенциалом и может быть продуктивно использован в различных областях, связанных с обработкой изображений и анализом данных, в частности, применен для эффективного управления дорожным движением, обеспечения равномерной загрузки транспортной сети на пределе ее пропускной способности, не допуская перегрузки уязвимых зон, а также прогнозирования развития транспортной обстановки. Он способствует ускорению алгоритма детектирования транспортных средств на спутниковых снимках, позволяет оценивать состояние дорожного движения и эффективность его организации, выявлять и прогнозировать развитие процессов, влияющих на состояние дорожного движения, а также контролировать сферу безопасности и организации дорожного движения.

**Ключевые слова:** нейронная сеть, система управления транспортным потоком, детектирование, распознавание образов, селективный поиск, обучающая выборка, спутниковые снимки, компьютерное зрение

**Для цитирования:** Пугачев И. Н., Тормозов В. С. Разработка метода детектирования объектов транспортных потоков по спутниковым фотоснимкам сверхвысокого разрешения // Вестн. ДВО РАН. 2024. № 2. С. 33–41. <http://dx.doi.org/10.31857/S0869769824020033>, EDN: ldnkmo

**Финансирование.** Работа выполнена при поддержке Минобрнауки РФ, дополнительное соглашение от 21.04.2020 № 075-02-2020-1529/1.

Original article

# Development of a method for detecting traffic flow objects from satellite photographs with high image quality

I. N. Pugachev, V. S. Tormozov

*Igor N. Pugachev*

Doctor of Sciences in Technics, Associate Professor

Khabarovsk Federal Research Center of the FEB RAS, Khabarovsk, Russia

[ipugachev64@mail.ru](mailto:ipugachev64@mail.ru)

<https://orcid.org/0000-0003-0345-4350>

*Vladimir S. Tormozov*

Candidate of Sciences in Technics, Associate Professor

Pacific State University, Khabarovsk, Russia

[007465@pnu.edu.ru](mailto:007465@pnu.edu.ru)

<https://orcid.org/0000-0002-5628-858X>

**Abstract.** A set of algorithms used to recognize objects in high-quality satellite photographs is described. This method has a unique ability to detect objects whose dimensions in images do not exceed several tens of pixels. In a photograph, each distinctive area of the image is examined to determine the presence of an object of a certain class, and the probability of this presence in the area in question is calculated. Based on the results of image analysis, a conclusion is drawn about the presence and probable location of the object. A detailed explanation is also given of how the algorithms used in the detection process are learned and parameterized. Taking into account the research results, a wide range of processes can be automated, for example, simplifying the collection and analysis of data in numerous analytical systems. The method has enormous potential and can be effectively used in various fields related to image processing and data analysis, in particular, used for effective traffic management, ensuring uniform loading of the transport network at the limit of its capacity, avoiding overloading of vulnerable areas, as well as forecasting the development of the transport situation. It helps speed up the algorithm for detecting vehicles on satellite images, allows you to assess the state of road traffic and the effectiveness of its organization, identify and predict the development of processes affecting the state of road traffic, as well as monitor the field of safety and traffic management.

**Keywords:** neural network, traffic flow control system, detection, pattern recognition, selective search, training set, satellite images, computer vision

**For citation:** Pugachev I. N., Tormozov V. S. Development of a method for detecting traffic flow objects from satellite photographs with high image quality. *Vestnik of the FEB RAS*. 2024;(2):33–41. <http://dx.doi.org/10.31857/S0869769824020033>, EDN: ldnkmo

**Funding.** The work was supported by the Ministry of Science and Education of the Russian Federation, supplementary agreement dated April 21, 2020 N075-02-2020-1529/1.

## Введение

Транспортные системы городов сегодня перегружены, а системы мониторинга громоздки, дорогостоящи и не отражают единовременной целостной картины. Требуется новая технологическая платформа, обеспечивающая доступный, достоверный, комплексный мониторинг систем. В связи с этим тема исследований, направленных на разработку методологии применения материалов космического зондирования земли для решения задач мониторинга и оптимизации транспортной инфраструктуры, весьма актуальна.

Космические снимки сверхвысокого (от 0,3 до 1 м) пространственного разрешения могут отображать большие территории, в частности территории различных населенных пунктов – от мелких до крупных городов [1].

Нашей целью являлась разработка метода детектирования и классификации объектов для оценки интенсивности и состава транспортного потока по спутниковым снимкам сверхвысокого разрешения и географической информации о расположении и ширине дорог. Основными задачами исследования стали: анализ алгоритмов и методов оценки показателей транспортного потока (ТП) с использованием спутниковых снимков сверхвысокого разрешения, а также алгоритмов детектирования и классификации транспортных средств (ТС) на таких снимках; разработка алгоритма извлечения со снимков изображений отдельных перегонов дорожной сети.

Из перечня основных параметров дорожного движения следует выделить два: состав ТП и количество ТС, приходящихся на один километр полосы движения (плотность движения). Данные параметры возможно определять фактически, а не расчетом единовременно на всей улично-дорожной сети (УДС) города, в различные периоды времени, с применением космических снимков сверхвысокого пространственного разрешения.

## Материалы и методы исследований

Одним из факторов, осложняющих детектирование и классификацию ТС, является то, что снимки с очень высоким разрешением, от 0,3 до 1 м, могут содержать только несколько пикселей для установления размеров и характеристик ТС. Например, автомобиль размером 3200 на 1420 мм будет представлен всего лишь 3 пикселями в длину и 1 пикселем в ширину. Это сильно осложняет их распознавание и классификацию.

Для исследования была создана экспериментальная система «TDC extractor» с использованием методов цифровой обработки изображений, распознавания образов и машинного обучения для обнаружения и классификации транспортных средств на конкретном участке УДС [2, 3]. В качестве базы для построения программной системы была выбрана библиотека глубокого обучения *Caffe*, написанная на языке программирования C++. Программная система включает в себя несколько основных компонентов:

1. Модуль сужения области детектирования, использующий географические данные о расположении дорожных участков в городе для сужения области поиска ТС.
2. Модуль генерации гипотез, который включает алгоритмы селективного поиска и их фильтрации, основан на низкочастотной информации и размерах объектов.
3. Модуль распознавания визуальных объектов, основанный на сверточной нейронной сети второго порядка. Модуль распознавания визуальных объектов решает задачи определения принадлежности гипотезы одному из классов ТС: легковое авто, грузовое авто, автобус, мототранспорт.

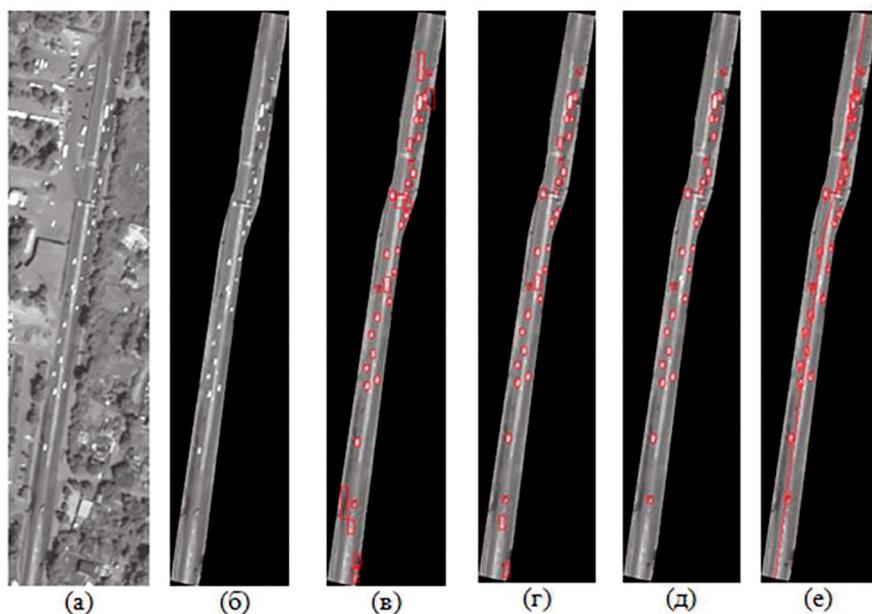


Рис. 1. Базовые стадии работы метода детектирования и классификации ТС: *a* – участок спутникового снимка, включающий в себя изображение перегона; *б* – изображение перегона в рамках рассматриваемого участка, полученное программной реализацией алгоритма сокращения области поиска; *в* – множество гипотез, полученных модифицированным алгоритмом селективного поиска; *г* – набор гипотез, оставшихся в результате выполнения фильтрации по низкочастотной информации и по размерам; *д* – множество детектированных ТС, для которых была выполнена классификация; *е* – ТС с определенным направлением движения, полученным исходя из относительной позиции на дорожном полотне

Модули, которые решают проблемы обнаружения и классификации транспортных средств, включают все вышеперечисленные составные компоненты. В данной статье не рассматриваются модули, выполняющие расчеты числовой оценки показателей транспортного потока.

На рис. 1 изображен процесс обнаружения и классификации транспортных средств методом обработки спутниковых изображений. Конечным результатом работы системы является численное значение транспортных средств, обнаруженных на каждом этапе процедуры детектирования, по категориям и направлениям движения [4].

В ходе проведенных исследований на программной системе «TDC extractor» были качественно оценены разработанные алгоритмы, составляющие систему детектирования и классификации: алгоритмов сокращения области поиска, алгоритмов выборочного поиска с фильтрацией гипотез.

Для обучения нейронной сети создаются две базы из обучающей и тестирующей выборки, которые записываются в базу данных формата *lmbd* (*Lightning Memory-Mapped Database*). Данная база представляет собой высокопроизводительную встроенную транзакционную базу данных и созданных к ним масок.

После детектирования необходимо классифицировать транспортные средства по типам. Классификация будет осуществляться с помощью семантической классификации с использованием сверточных нейронных сетей (*Convolutional Neural Network – ConvNet/CNN*). Для глубокого обучения нейронной сети существует большое разнообразие различных программных библиотек.

Искусственные нейронные сети могут менять свое поведение в зависимости от внешней среды. Данный фактор в большей степени, чем любой другой, ответствен за тот интерес, который они вызывают. После предъявления входных сигналов (возможно, вместе с требуемыми выходами) они самостоятельно настраиваются, чтобы обеспе-

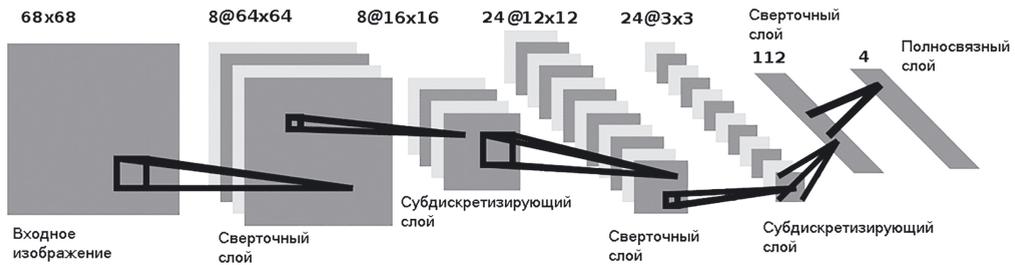


Рис. 2. Структурная схема используемой CNN

чивать требуемую реакцию. Было разработано множество обучающих алгоритмов, каждый со своими сильными и слабыми сторонами. Все еще существуют проблемы относительно того, чему нейронная сеть может обучиться и как обучение должно проводиться.

Это показывает, что работы предлагаемого направления являются актуальными на сегодняшний момент.

Для проведения исследований была выбрана среда обучения *Caffe*, разработанная Яньцинем Цзя в университете Беркли. Данная библиотека, поддерживающая множество типов машинного обучения, нацелена в первую очередь на решение задач классификации и сегментации. Для того чтобы построить и обучить модель распознавания в библиотеке, объявлена функция *Caffe* с параметром обучения (*train*) и входным файлом, определяющим структуру и базовые параметры модели. На выходе получится файл формата *caffemodel*, используемый для сохранения и перенесения модели.

На рис. 2 показана общая схема сверточной нейронной сети, использованной в данной работе. Приведены количество и размер карт признаков для каждого слоя, а также формулы для вычисления значений, проходящих через сигнальные слои.

Кроме того, было исследовано качество разработанного алгоритма, в том числе модулей сужения области поиска и выборочного поиска с допущениями фильтрации. Сверточная нейронная сеть была обучена на 100 раундов.

### Результаты исследований и их обсуждение

Проанализированы результаты проведенных экспериментов. Анализ показал, что увеличение размера обучающей выборки приводит к улучшению качества сети [4]. На рис. 3 показан график зависимости ошибки обучения CNN от количества эпох для различных размеров обучающей выборки. Минимальная ошибка обучения на предъявляемом алгоритму наборе была равна 1%. Минимальная ошибка тестирования составила 7,3%.

В таблице показаны данные каждого слоя (количество и размер ядер свертки) и формула расчета для каждого слоя свертки, слоя подвыборки и полносвязного слоя.

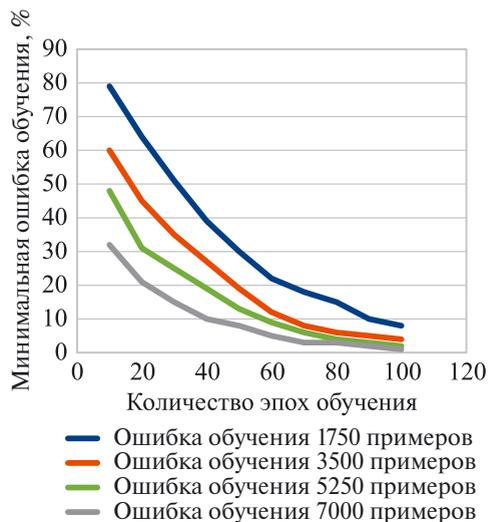


Рис. 3. Полученные в результате исследования графики зависимости ошибки обучения CNN от количества эпох обучения (1750, 3500, 5250, 7000 примеров в обучающей выборке)

### Структура используемой CNN

№ п/п	Слой	Размеры ядра	Количество каналов	Формулы формирования сигнала
	Вход			Входное изображение $68 \times 68$
1	Сверточный слой C1 (с нейронами 2-го порядка) на выходе 16 каналов $63 \times 4$	$5 \times 5$	8	$y_j = f\left(\sum_{i=1}^m (w_{ji}(k)y_i(k) + u_{ji}(k)y_i^2(k))\right)$
2	Субдискретизирующий слой S1 на выходе 16 каналов	$4 \times 4$	8	$y_j = f(a_j \max(y_j))$
3	Сверточный слой C2 (с нейронами 2-го порядка)	$5 \times 5$	24	$y_j = f\left(\sum_{i=1}^m (w_{ji}(k)y_i(k) + u_{ji}(k)y_i^2(k))\right)$
4	Субдискретизирующий слой S2	$4 \times 4$	24	$y_j = f(a_j \max(y_j))$
5	Сверточный слой C3	$3 \times 3$	112	$y_j = f\left(\sum_{i=1}^m (w_{ji}(k)y_i(k))\right)$
6	Полносвязный слой F			$y_j = f\left(\sum_{i=1}^n (w_{ji}(k)y_i(k))\right)$
Выход		4 классификационных сигнала от полносвязного слоя		

В вышеприведенной таблице  $f(\dots)$  – сигмоидальная функция активации нейронов сети:

$$f(x) = \frac{1}{1 + e^{-x}}.$$

Нейроны более высокого порядка могут быть введены в любой слой CNN: сверточный и полносвязный слои, даже слои субдискретизации. Однако добавление различных типов слоев может по-разному влиять на характеристики нейронной сети, такие как точность распознавания объектов и способность к обобщению, вследствие чего и влияние на результат работы сети будет различным. В ходе исследования было установлено, что первый и второй сверточные слои оказались лучшим выбором для внедрения нейронов второго порядка. Нецелесообразно использовать нейроны на третьем сверточном слое, поскольку это приводит к увеличению вычислительной сложности без улучшения качества нейронной сети.

Оригинальность исследований состоит в использовании исходных данных, полученных с применением космических снимков для построения транспортных моделей территории, с решением задач подбора космических материалов, условий съемки, оптимизации. Предлагаемая методика построения транспортной модели территории на основе данных космического зондирования включает в себя необходимые процедуры: процедура определения оптимальных параметров космической съемки, изучение вероятных вариантов схемы классификации объектов, вариантов анализа и оптимизации сети.

Нейронная сеть обрабатывает изображение каждой из детектированных гипотез, связывая его с одной из категорий ТС. Проводится полное обнаружение и классификация транспортных средств. Однако для оценки метрик транспортного потока помимо выявления соответствия между транспортными средствами и участками дороги необходимо также определить направление, в котором транспортные средства движутся по дороге при двустороннем движении. С этой целью был разработан алгоритм, основанный на положении обнаруженного транспортного средства относительно осевой линии интерполированной модели дороги.

Производится определение, на какой половине дороги находится центральная точка минимального ограничивающего прямоугольника (BoundingBox) обнаруженного автомобиля. То есть при рассмотрении интерполированной цифровой модели перегона устанавливают, с какой стороны относительно ломаной цепочки отрезков перегона находится центральная точка ТС.

Для определения направления движения на участке дороги используются следующие обозначения. Направления движения нумеруются с нулевым индексом, если для каждой точки, лежащей на полосе перегона, выполняется соотношение:

$$x > x_o,$$

где  $x$  – абсцисса рассматриваемой точки;  $x_o$  – абсцисса точки основания перпендикуляра, проведенного от рассматриваемой точки к осевой линии интерполированной модели перегона (рис. 4).

Если соотношение не выполняется, индекс направления движения транспортного средства, находящегося на соответствующей полосе, равен 1.

Таким образом, алгоритм определения направления дорожного движения по BoundingBox ТС, включает в себя следующие этапы:

*Шаг 1.* Расчет координат центральной точки ТС:

$$\left( x_{bb} + \frac{w_{bb}}{2}; y_{bb} + \frac{h_{bb}}{2} \right),$$

где  $(x_{bb}; y_{bb})$  – координаты BoundingBox ТС;  $w_{bb}, h_{bb}$  – ширина и высота BoundingBox ТС.

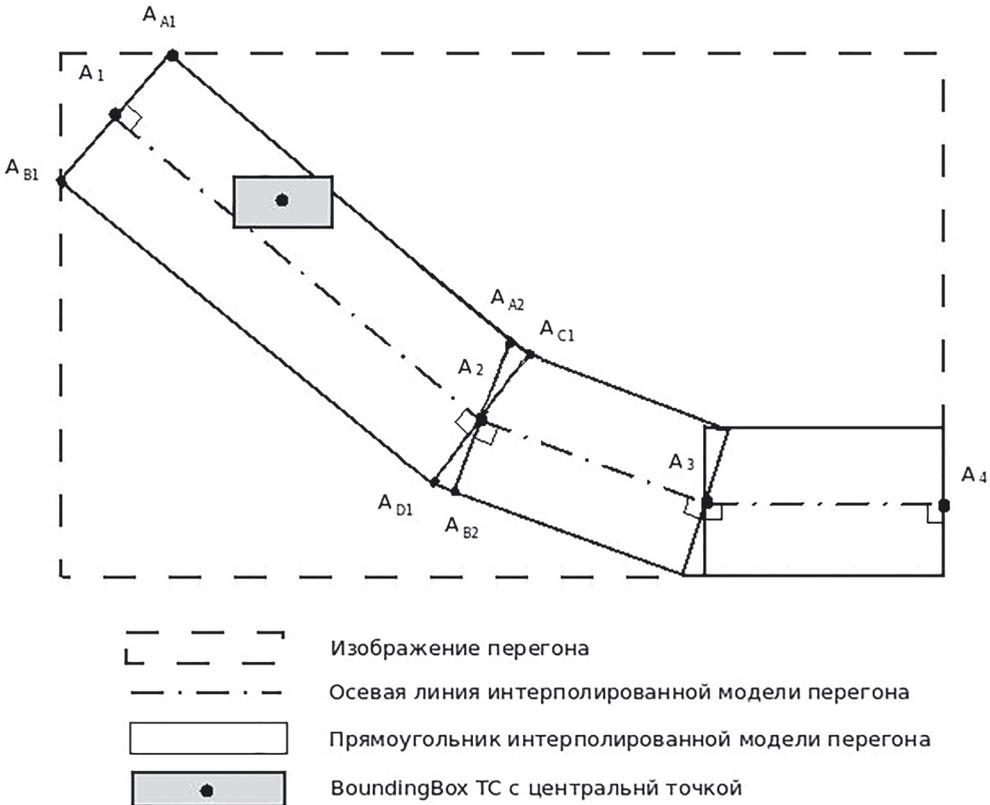


Рис. 4. Направление трафика, определяемое путем нахождения центральной точки гипотенузы и ее положения по отношению к центральной линии интерполированной модели пролетов

*Шаг 2.* Нахождение перпендикуляра с минимальной длиной к одной из прямых, построенных на основе отрезков ломаной рассматриваемого перегона.

*Шаг 3.* Если неравенство верно, то это означает, что центральная точка находится по одну сторону от ломаной, и транспортное средство движется прямо. При нахождении центральной точки по другую сторону предполагается, что движение обратное. Для этого нужно найти отношение координат точки основания перпендикуляра и центральной точки ТС.

## **Выводы**

Информация, собранная с орбитальных носителей в виде данных дистанционного зондирования (ДЗЗ), представляет собой всеобъемлющий и разнообразный источник знаний о наземных объектах [5–11]. Обнаружение и категоризация объектов в транспортном потоке, представленных на спутниковых снимках, является важнейшим аспектом решения проблемы интерпретации данных, полученных от систем ДЗЗ. Данная система исследований и разработок позволяет детектировать и классифицировать ТС на снимках с высоким пространственным разрешением, учитывая все описанные проблемы, возникающие при этом процессе.

Разрабатываемая алгоритмическая схема позволит производить численную оценку интенсивности и состава ТП по каждому перегону дорожной сети и может улучшить фактографическое обеспечение процессов транспортного планирования и повысить качество систем управления дорожным движением.

Мониторинг безопасности и организации дорожного движения будет проводиться чаще, чем предполагает «Порядок мониторинга дорожного движения» (утвержден приказом Минтранса России от 18 апреля 2019 г. № 114), поскольку предлагаемый метод оценивает состояние дорожного движения и его эффективность. Кроме того, он определяет и прогнозирует развитие процессов, влияющих на условия дорожного движения.

Решение задач формирования и развития транспортной инфраструктуры требует учета большого количества факторов, связанных с показателями технического развития города, ростом потребностей предприятий и населения, ресурсными возможностями. Требование учета временной динамики ресурсных ограничений совместно с динамикой специфики решаемых задач и потребностей в транспортных (дорожных) ресурсах приводит к объективной необходимости сформулировать научно обоснованный подход, позволяющий оптимизировать процессы совершенствования базовых магистральных транспортных связей на муниципальном уровне.

## **СПИСОК ИСТОЧНИКОВ**

1. Пугачев И.Н., Маркелов Г.Я., Тормозов В.С. Методика подсчета транспортных средств с использованием космических снимков сверхвысокого пространственного разрешения // Вестн. ТОГУ. 2017. № 2 (45). С. 13–20.
2. Пугачев И.Н., Маркелов Г.Я., Тормозов В.С. Ускорение алгоритма детектирования транспортных средств на спутниковых снимках с помощью процедуры фильтрации гипотез // Вестн. Рос. нов. ун-та. Серия: Сложные системы: модели, анализ, управление. 2019. № 1. С. 130–139.
3. Chen Ch., Минальд А.А., Богуш Р.П., Ма G., Weichen Y., Абламейко С.В. Обнаружение и классификация транспортных средств на снимках сверхвысокого разрешения с помощью нейронных сетей // Журн. прикл. спектроскопии. 2022. Т. 89. № 2. С. 275–282.
4. Пугачев И.Н., Маркелов Г.Я., Тормозов В.С. Обучение и использование сверточной нейронной сети для детектирования и классификации транспортных средств на спутниковых снимках сверхвысокого разрешения // Пром. АСУ и контроллеры. 2019. № 10. С. 20–25.
5. Головин О.К. Системный анализ и моделирование объектов, процессов и явлений транспортной инфраструктуры в технических системах управления // Изв. Самар. науч. центра РАН. 2018. Т. 20, № 6–2 (86). С. 301–310.

6. Бобырь М.В., Архипов А.Е., Якушев А.С., Бхаттачарья С. Построение карты глубины с использованием модернизированного фильтра Канни. Ч. 2 // Пром. АСУ и контроллеры. 2021. № 5. С. 3–15.
7. Пашаев М.Я. Управление системами транспортной логистики на основе ГЛОНАСС // Вестн. Астрахан. гос. техн. ун-та. Серия: Управление, вычислительная техника и информатика. 2017. № 3. С. 143–148.
8. Филиппова Н.А., Мушта Б.М., Сидоренко А.В. Анализ развития навигационной системы диспетчерского управления грузовым транспортом // Синергия наук. 2019. № 36. С. 734–751.
9. Исаева Е.И., Сорокин Е.А. Оценка эффективности от внедрения навигационных спутниковых технологий при перевозках в международном сообщении // Актуальные вопросы организации автомобильных перевозок, безопасности движения и эксплуатации транспортных средств: сб. науч. тр. по материалам XIV Междунар. науч.-техн. конф. Саратов, 2019. С. 97–104.
10. Петрова Е.А. Снижение издержек транспортного предприятия с помощью цифровых технологий // Проблемы совершенствования организации производства и управления промышленными предприятиями: межвуз. сб. науч. тр. Самара, 2021. № 1. С. 228–231.
11. Михеева Т.И., Головнин О.К., Федосеев А.А. Интеллектуальная геоинформационная платформа исследования транспортных процессов // Информационные технологии и нанотехнологии (ИТНТ-2017): сб. тр. III Междунар. конф. и молодежной школы / Самар. нац. исслед. ун-т им. акад. С.П. Королева. Самара, 2017. С. 753–761.

## REFERENCES

1. Pugachev I.N., Markelov G. Ya., Tormozov V.S. Technique for counting vehicles using space images of ultra-high spatial resolution. *Bulletin of Pacific National University*. 2017;45(2):13–20. (In Russ.).
2. Pugachev I.N., Markelov G. Ya., Tormozov V.S. Acceleration of the vehicle detection algorithm on satellite images using the hypothesis filtering procedure. *Bulletin of the Russian New University. Series: Complex Systems: Models, Analysis, Control*. 2019;(1):130–139. (In Russ.).
3. Chen Ch., Minald A.A., Bogush R.P., Ma G., Weichen Y., Ablameiko S.V. Detection and classification of vehicles in ultra-high resolution images using neural networks. *Journal of Applied Spectroscopy*. 2022;89(2):275–282. (In Russ.).
4. Pugachev I.N., Markelov G. Ya., Tormozov V.S. Training and use of a convolutional neural network for the detection and classification of vehicles on ultra-high resolution satellite images. *Industrial ACS and Controllers*. 2019;(10):20–25. (In Russ.).
5. Golovnin O.K. System analysis and modeling of objects, processes and phenomena of transport infrastructure in technical control systems. *Proceedings of the Samara Scientific Center of the Russian Academy of Sciences*. 2018;20(6–2):301–310. (In Russ.).
6. Bobyr M.V., Arkhipov A.E., Yakushev A.S., Bhattacharya S. Building a depth map using the upgraded Canny filter. Part 2. *Industrial ACS and Controllers*. 2021;(5):3–15. (In Russ.).
7. Pashaev M. Ya. Management of transport logistics systems based on GLONASS. *Bulletin of the Astrakhan State Technical University. Series: Management, Computer Technology and Informatics*. 2017;(3):143–148. (In Russ.).
8. Filippova N.A., Mushta B.M., Sidorenko A.V. Analysis of the development of the navigation system of dispatch control of freight transport. *Synergy of Sciences*. 2019;(36):734–751. (In Russ.).
9. Isaeva E.I., Sorokin E.A. Evaluation of the effectiveness of the implementation of navigation satellite technologies for transportation in international traffic. In: *Topical Issues of the Organization of Road transport, Traffic Safety and Operation of Vehicles*: Collection of scientific papers based on the materials of the XIV International Scientific and Technical Conference. Saratov; 2019. P. 97–104. (In Russ.).
10. Petrova E.A. Reducing the costs of a transport enterprise with the help of digital technologies. In: *Problems of improving the organization of production and management of industrial enterprises*: Interuniversity collection of scientific papers. Samara; 2021. N1. P. 228–231. (In Russ.).
11. Mikheeva T.I., Golovnin O.K., Fedoseev A.A. Intelligent geoinformation platform for the study of transport processes. In: *Information technologies and nanotechnologies (ITNT-2017)*. Proceedings of the III International Conference and Youth School. Samara; 2017. P. 753–761. (In Russ.).