

УДК 656.11:625.71

## РАЗРАБОТКА НОВОГО МЕТОДА ДЕТЕКТИРОВАНИЯ И КЛАССИФИКАЦИИ ТРАНСПОРТНЫХ СРЕДСТВ ПО СПУТНИКОВЫМ ИЗОБРАЖЕНИЯМ

Д-р техн. наук **И.Н. Пугачев**  
(Хабаровский федеральный исследовательский центр  
Дальневосточного отделения  
Российской академии наук (ХФИЦ ДВО РАН)),  
канд. техн. наук **В.С. Тормозов**  
(Тихоокеанский государственный университет)  
Конт. информация: [ipugachev64@mail.ru](mailto:ipugachev64@mail.ru);  
[007465@pnu.edu.ru](mailto:007465@pnu.edu.ru)

*Эффективное управление дорожным движением должно обеспечивать равномерную загрузку транспортной сети на пределе ее пропускной способности, не допуская перегрузки уязвимых зон, а также прогнозировать развитие транспортной обстановки. Предлагается метод ускорения алгоритма детектирования транспортных средств на спутниковых снимках. Подход основан на применении процедуры фильтрации гипотез после селективного поиска по определенным параметрам. Благодаря этому сокращается количество гипотез, обрабатываемых алгоритмом распознавания, и происходит ускорение работы алгоритма детектирования. Данный метод позволит 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:** *безопасность дорожного движения, система управления транспортным потоком, детектирование, распознавание образов, селективный поиск, спутниковые снимки, компьютерное зрение.*

Методы оценки показателей транспортных потоков (ТП) в условиях города могут быть использованы для эффективного перераспределения транспортных средств (ТС) на улично-дорожной сети (УДС). С ростом автомобилизации населения появляется потребность подобной оценки на сетевом уровне для рационального использования инфраструктуры автомобильных дорог и дорожного хозяйства.

К существующим на данный момент методам оценки параметров дорожного движения ТП можно отнести: ручной подсчет и классифика-

цию ТС; использование индукционных датчиков, радиолокаторов, инфракрасных излучателей; оценку состава ТП с использованием видеокамер, установленных над дорожным полотном и автоматически регистрирующих номера проходящих автомобилей [1-3]. Однако ручной подсчет требует значительных человеческих и материальных ресурсов. Индукционные датчики и видеокамеры могут быть размещены только локально в узлах УДС и также требуют установки дорогостоящего оборудования для фиксации, сбора и обработки данных о ТП. Отсутствие свободно распространяемых и легко доступных средств сбора данных препятствует широкому развитию исследований в области оценки показателей ТП.

В данной статье предлагается метод детектирования и классификации ТС, находящихся в ТП, с применением космических снимков сверхвысокого (от 0,3 м до 1 м) пространственного разрешения, которые могут отображать всю территорию города.

Согласно документу [4], 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, одновременно на всей УДС города, в различные периоды времени, с применением космических снимков сверхвысокого пространственного разрешения.

Среди проблем, возникающих при детектировании и классификации ТС на снимках сверхвысокого (от 0,3 м до 1 м) пространственного разрешения, можно выделить следующие [5]:

1. Определяемые объекты на изображениях такого разрешения имеют размер в несколько пикселей и при плотных потоках сливаются друг с другом.
2. На дорожном полотне, кроме ТС, наблюдаются и другие объекты: дорожные знаки; лужи; тени, отбрасываемые зданиями и деревьями вблизи дороги.
3. Дорожное полотно может быть зрительно трудноразличимо от других наземных объектов: близлежащих домов, тротуаров и других объектов.
4. Дороги имеют несколько полос движения.
5. Дорожное полотно и ТС на нем могут быть перекрыты облаками или эстакадами. В подобных ситуациях распознавание наземных ТС в видимом спектре очевидно невозможно. Кроме того, воз-

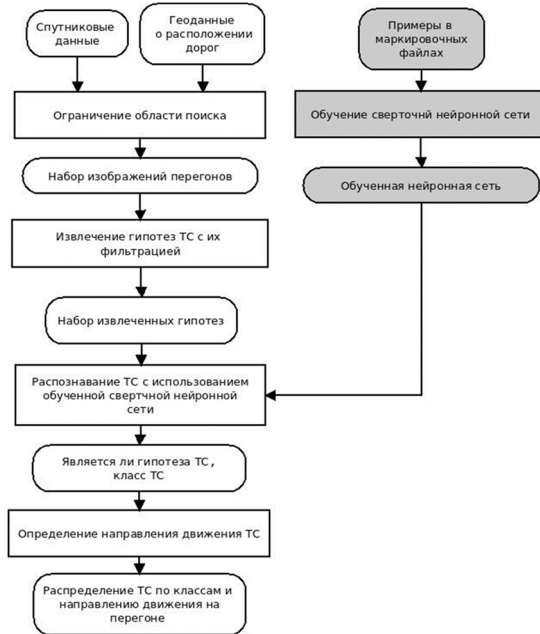
можно окклюзии дорожного полотна с растительностью и зданиями.

6. На дорогах может наблюдаться высокая плотность транспортного потока, могут формироваться очереди ТС (например, перед светофором). При этом примыкающие ТС на снимке во многих ситуациях возможно будут трудно различимы друг от друга. Например, два легковых автомобиля одного цвета могут быть идентифицированы как грузовой автомобиль того же цвета.
7. Диапазон снимков сверхвысокого разрешения – от 0,3 м до 1 м. Так, например, для автомобиля ВАЗ 1111 «Ока» длиной 3200 мм, шириной 1420 мм на снимке с разрешением 1 м на пиксель его габариты составляют: 3 пикселя – длина; 1 пиксел – ширина. Следовательно, такое ТС на снимке будет характеризоваться 3 пикселями, отличающимися от фона. В данном случае приведены наихудшие для распознавания характеристики разрешения и размеров ТС.


Предлагаемый метод детектирования ТС на спутниковых снимках включает в себя несколько основных этапов. На **рис. 1** показаны основные этапы и соответствующие им результаты, которые используются в последующей обработке. Каждый этап метода изображен в виде прямоугольника. Данные, используемые в методе, изображены в виде прямоугольников со скругленными углами. Этапы процедуры обучения отмечены отдельно серым цветом. Входными данными для рассматриваемого метода детектирования и классификации являются: множество одномоментных спутниковых снимков сверхвысокого пространственного разрешения, численное значение пространственного разрешения спутниковых снимков (метров на пиксель), географическая информация о местоположении на местности и ширине дорог. Геоинформация должна находиться в той же системе координат, что и спутниковые снимки во избежание необходимости преобразования координат [5].

На **рис. 2** изображена структурная схема сверточной нейронной сети, которую использовали в рассматриваемой работе. На рисунке представлены количество и размер карт признаков на каждом слое, а также формулы для расчета значений проходящих через слои сигналов. Карты признаков представлены в виде квадратов серого цвета. Черные квадратные рамки отображают процесс наложения ядер на карту признаков и вычисление соответствующего значения ячейки следующей карты признаков. Два прямоугольника на конце сверточной сети обозначают полносвязный слой со 112-ю входными нейронными связями и

4-я выходами. Наличие сигнала на одном из выходов сети классифицирует объект на входном изображении как один из 4-х возможных классов ТС: легковой автомобиль, грузовой автомобиль, автобус, мотоцикл. Отсутствие сигнала на всех выходах сети означает, что объект не принадлежит ни одному из классов и вообще не является ТС.



**Рис. 1. Общая схема процесса детектирования и классификации ТС на спутниковых снимках**

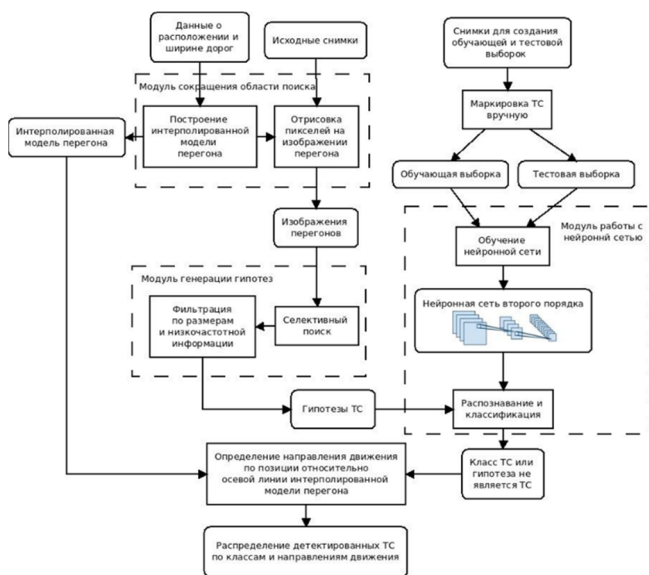


**Рис. 2. Архитектура используемой сверточной нейронной сети**

Для проведения исследований была создана экспериментальная система, предназначенная для детектирования и классификации ТС на перегонах УДС, с использованием методов цифровой обработки изображений, распознавания образов, методов машинного обучения. Система была создана на базе библиотеки глубокого обучения Caffe. Данная программная система включает следующие компоненты:


1. Модуль сокращения области поиска с использованием географических данных о расположении участков дорог в городе.
2. Модуль генерации гипотез. Включает в себя алгоритмы селективного поиска и фильтрации гипотез по низкочастотной информации и размерам.
3. Модуль распознавания визуальных объектов, основой которого является сверточная нейронная сеть второго порядка. Определяет, имеется ли конкретная гипотеза ТС и если да, то к какому из четырех классов она относится: легковому автомобилю, грузовому автомобилю, автобусу, мототранспорту.

К модулям, решающим задачи детектирования и классификации ТС, относятся все выше указанные модули. Модуль, выполняющий расчеты для численной оценки показателей транспортного потока, в данной статье не рассматривается. Модульная структура программной системы детектирования и классификации представлена на **рис. 3**.



**Рис. 3. Модульная структура системы детектирования и классификации**

На **рис. 4** отображен процесс обработки спутниковых снимков методом детектирования и классификации ТС. Окончательным результатом работы этой системы являются значения численного распределения детектированных ТС по классам и направлениям движения для каждого перегона УДС [6].




**Рис. 4. Этапы детектирования и классификации ТС:**

*а) часть спутникового снимка, содержащая в себе изображение перегона; б) извлеченное алгоритмом сокращение области поиска изображения перегона; в) набор гипотез, выделенных алгоритмом селективного поиска; г) гипотезы, оставшиеся после фильтрации по размерам и по низкочастотной информации; д) детектированные и классифицированные СНС ТС; е) определение направления движения ТС, исходя из расположения на дорожном полотне*

Кроме того, были проведены исследования качества работы разработанных алгоритмов, входящих в систему детектирования и классификации: алгоритма сокращения области поиска; алгоритма селективного поиска с фильтрацией гипотез.

*Алгоритм сокращения области поиска  
с использованием геоинформации о дорогах*

Данный алгоритм основан на разработанной интерполированной модели границ перегона. Так как область дорожного перегона на местности может содержать в себе кривые линии, в рассматриваемой работе область поиска ограничена приближенной, т.е. интерполированной моделью дорожного перегона. Пример интерполированной модели дорожного перегона представлен на **рис. 5**.



**Рис. 5. Схема интерполированной модели дорожного перегона и принципов ее построения**

В такой модели осевая линия дороги может быть смоделирована ломаной и задана последовательностью образующих ее точек  $A_1, A_2, \dots, A_n$ . Вся область перегона строится относительно этой смоделированной осевой линии. Относительно каждого отрезка ломаной строится прямоугольник, ширина которого равна ширине дорожного полотна перегона на снимке, а отрезок соединяет центры соответствующих отрезков. Таким образом, для формирования области поиска

---

---

внутри перегона со спутникового снимка извлекается цепочка прямоугольников, соприкасающихся друг с другом центральными точками соседних отрезков.

### *Селективный поиск с фильтрацией гипотез*

Селективный поиск – это часть алгоритма обнаружения объектов на изображении, извлекающая гипотезы о местоположении объекта. Каждая гипотеза представляет собой прямоугольник, внутри которого может быть вписан искомый объект, параллельный осям, ограничивающим прямоугольник (BoundingBox). Селективный поиск, как правило, работает в паре с алгоритмом распознавания объекта: каждая гипотеза подается на вход алгоритма распознавания, который выдает заключение, содержит ли гипотеза искомый объект. Можно заключить, что алгоритм распознавания выполняет классификацию гипотез на два класса: «объект» и «не объект». Селективный поиск извлекает гипотезы значительно быстрее, чем, например, алгоритм скользящего окна.

Обобщенная схема селективного поиска с фильтрацией гипотез ТС представлена на **рис. 6**. Вычисление общей меры схожести осуществляется на основе значений четырех частных мер схожести: по цвету, по текстуре, по размеру и по заполнению. Соседними областями являются области, имеющие общую границу или часть границы. Две соседние области с максимальной мерой схожести объединяются и формируют новую гипотезу. При переборе всех гипотез из набора – завершение алгоритма.

В **табл. 1** представлены результаты эксперимента по оценке улучшения алгоритма детектирования и классификации с помощью внедрения процедуры фильтрации гипотез: фильтрации только по размеру, только по низкочастотной информации и фильтрации по обоим этим характеристикам. В строках отображены результаты: количество верно детектированных ТС (TP), количество ложно детектированных объектов, не ТС (FP), количество ложно не детектированных ТС (FN), точность и полнота детектирования. В скобках представлены аналогичные результаты экспериментов только для алгоритма фильтрации гипотез. Такие результаты свидетельствуют о положительном вкладе процедуры фильтрации для метода детектирования и классификации в целом.



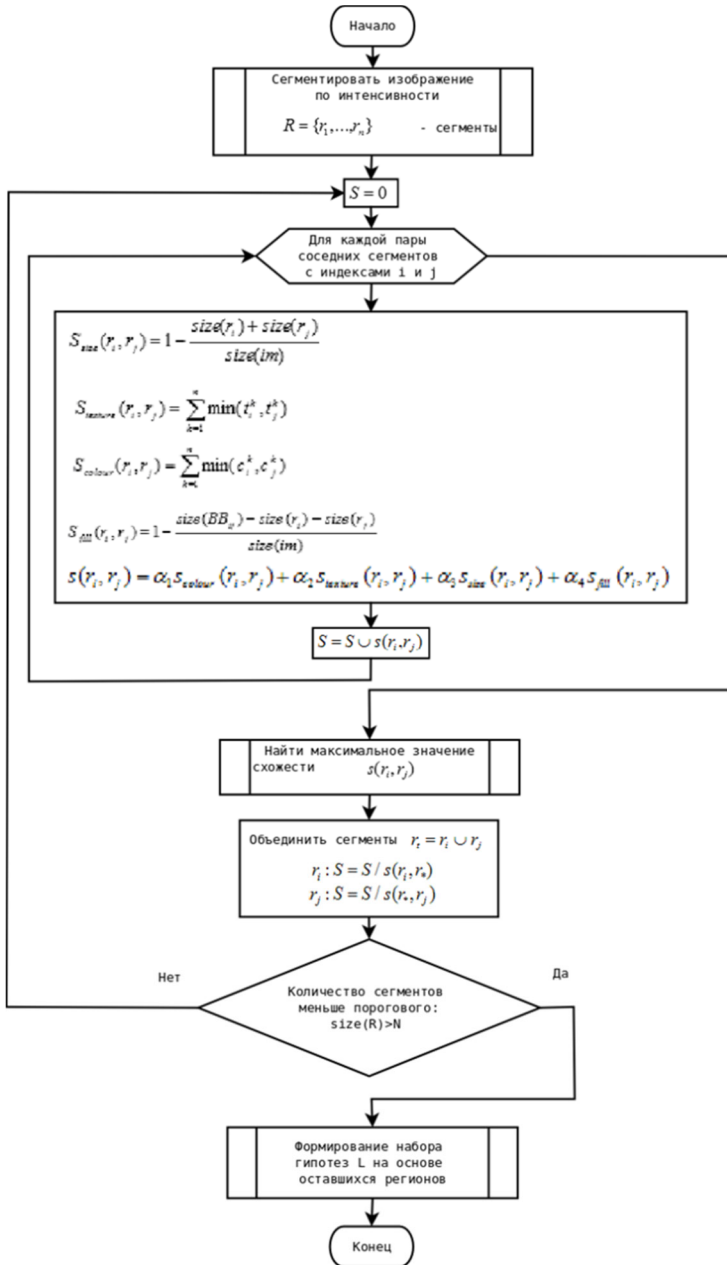


Рис. 6. Блок схема применяемого алгоритма селективного поиска

Таблица 1

*Результаты эксперимента по сравнению работы алгоритма распознавания ТС на ранее извлеченном изображении перегона с усовершенствованным алгоритмом селективного поиска, с фильтрацией по размерам, по низкочастотной информации и с обычным алгоритмом*


<i>Применение алгоритма</i>	<i>Алгоритм селективного поиска</i>	<i>Фильтрация по размерам</i>	<i>Фильтрация по низкочастотной информации</i>	<i>Усовершенствованный алгоритм</i>
<i>Количество верно детектированных ТС (в скобках – количество верно оставшихся гипотез в алгоритме фильтрации)</i>	210	211 (219)	210 (220)	211 (220)
<i>Количество ложно детектированных объектов (в скобках – количество ложно оставшихся гипотез в алгоритме фильтрации)</i>	9	5 (11)	7 (13)	4 (7)
<i>Количество ложно не детектированных ТС (в скобках – количество ложно удаленных гипотез в алгоритме фильтрации)</i>	21	20 (12)	21 (11)	20 (11)
<i>Точность детектирования (в скобках – точность алгоритма фильтрации гипотез), %</i>	95,9	97,7 (95,22)	96,8 (94,4)	98,1 (96,9)
<i>Полнота детектирования (в скобках – полнота алгоритма фильтрации гипотез), %</i>	90,9	91,3 (95,2)	90,9 (95,2)	91,3 (95,2)
<i>Время работы системы, с</i>	1,4	1,3	1,4	1,3

Исходя из результатов экспериментов, представленных в табл. 1, следует, что усовершенствованный алгоритм селективного поиска сокращает вероятность ложного детектирования, но не так значительно, как алгоритм сокращения: при его использовании точность детектирования увеличилась на 2,3 %. Время работы системы снизилось на 7 %. Увеличение точности детектирования с сокращением гипотез только по размерам составило 1,9 %, а только по низкочастотной информации – 0,9 %.

### *Разработка архитектуры нейронной сети, используемой в алгоритме детектирования и классификации ТС*

Следующим этапом является распознавание изображений оставшихся гипотез посредством обученной сверточной сети. Обученная нейронная сеть используется для распознавания и одновременно для классификации ТС. Изображения гипотез масштабируются к размерам  $68 \times 68$ . Таким образом, на вход нейронной сети поступает отцентрированное изображение гипотезы размером  $68 \times 68$ . Каждая гипотеза подается на вход нейронной сети, которая в результате своей работы присваивает гипотезу одному из 4-х классов ТС, либо указывает, что ТС внутри гипотезы не обнаружено [7].

На рис. 7 изображена структурная схема сверточной нейронной сети (СНС), используемой в рассматриваемой работе. На рисунке представлены количество и размер карт признаков на каждом слое, а также формулы для расчета значений, проходящих через слои сигналов. Карты признаков представлены в виде квадратов серого цвета. Черные квадратные рамки отображают процесс наложения ядер на карту признаков и вычисление соответствующего значения ячейки следующей карты признаков. Два прямоугольника на конце сверточной сети обозначают полносвязный слой со 112-ю входными нейронными связями и 4-я выходами.



*Рис. 7. Структурная схема используемой СНС*

В представленной работе используется 3 сверточных слоя (C1, C2, C3), 2 субдискретизирующих слоя (S1, S2) и 1 полносвязный слой (F). Исходя из этого, наиболее оптимальным размером ядер субдискретизирующих слоев представляется  $4 \times 4$ . При этом для сверточных слоев оптимальным размером ядер является  $5 \times 5$ . Так как на сверточном слое используется ядро размерами  $5 \times 5$ , то размеры карт признаков на этом слое сокращаются на 4. На субдискретизирующих слоях размер карт признаков сокращается в 4 раза, поскольку размеры применяемого ядра –  $4 \times 4$ .

Таким образом, для определения оптимальных размеров карт признаков на каждом слое необходимо найти минимальное значение параметра  $n$  неравенства:

$$4(4n + 4) + 4 \geq 68; n \in N.$$

В неравенстве присутствует знак  $\geq$ , так как представляется лучшим добавлением шума в исходные данные нейронной сети, чем потеря части содержательной информации об объекте. Параметром  $n$  в данном неравенстве является размер карты признаков последнего сверточного слоя (C3). Минимальным значением этого параметра, исходя из приведенного выше неравенства, является  $n=3$ . В результате получаем карты признаков для сверточных и субдискретизирующих слоев нейронной сети с размерами, указанными **табл. 2**.

Таблица 2

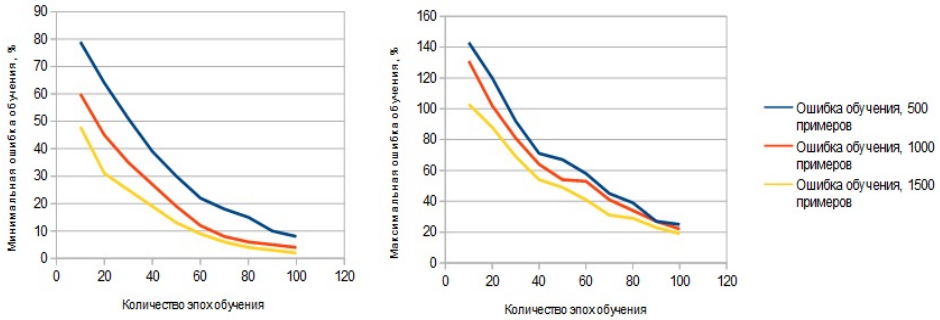
*Размеры карт признаков сверточной нейронной сети*

<i>Слой</i>	<i>C1</i>	<i>S1</i>	<i>C2</i>	<i>S2</i>	<i>C3</i>
<i>Размеры входной карты признаков</i>	68	64	16	12	$n=3$

Количество карт признаков для первых двух сверточных слоев выбрано таким же, как и в исследованиях, решающих задачу распознавания визуальных объектов: 8 – для первого сверточного слоя (C1) и 24 – для второго сверточного слоя (C2).

В ходе проведенного обучения применяемая сверточная сеть обучалась в течение 100 эпох. Минимальная достигнутая в ходе обучения ошибка на обучающей выборке составила 1 %, ошибка тестирования – 7,3 %. Графики зависимости ошибки обучения СНС от

количества проведенных эпох для разного размера обучающей выборки приведены на **рис. 8** **Ошибка! Источник ссылки не найден..** Анализ результатов исследования показал, что при увеличении размера обучающей выборки повышается качество работы СНС, выражающееся снижением ошибки обучения и тестирования [6].



**Рис. 8. Графики зависимости ошибки обучения СНС от количества эпох обучения (500, 1000, 1500 примеров в обучающей выборке)**

В ходе рассматриваемой работы были проведены исследования по оценке качества функционирования системы детектирования и классификации в целом. Для оценки качества работы разработанной системы детектирования и классификации были выполнены экспериментальные исследования. Экспериментальная оценка выполнялась с использованием данных спутниковой съемки г. Хабаровска. В качестве метрик для оценки качества работы применялись следующие параметры: точность (precision), полнота (recall), F-мера детектирования ТС и точность классификации. Точность (precision), полнота (recall), F-мера детектирования рассчитывались по формулам:

$$P = \frac{TP}{TP+FP}, \quad (1)$$

$$R = \frac{TP}{TP+FN}, \quad (2)$$

$$F = \frac{2 \cdot P \cdot R}{P+R}, \quad (3)$$

где

$P$  – точность детектирования;

$TP$  – количество верно детектированных ТС;

$FP$  – количество объектов, неверно детектированных как ТС;  
 $FN$  – количество недетектированных ТС;  
 $R$  – полнота детектирования;  
 $F$  – F-мера детектирования.

Для оценки качества классификации применялась одна метрика – точность классификации:

$$A = \frac{T_{class}}{TP+FP}, \quad (4)$$

где

$A$  – точность классификации (accuracy);  
 $T_{class}$  – количество верно классифицированных ТС.

Эксперименты проводились на спутниковых снимках г. Хабаровска, СНС предварительно была обучена на экземплярах ТС, представленных на снимках того же города, но в другое время съемки. Для различного количества примеров, участвовавших в обучении СНС, было оценено качество детектирования и классификации.

Проведенные исследования показали, что с увеличением числа обучающих примеров происходит рост качества детектирования и классификации ТС, выражающееся через численный рост метрик. Однако на определенном уровне обученности СНС увеличение числа примеров дает незначительный вклад в рост качества работы системы. Замеры метрик системы проводились, начиная с обучающей выборки размером 100 примеров и далее с нарастанием количества примеров на 200, до 1500 примеров в выборке. Замер выполнялся только на СНС, обученной на обучающей выборке в течение 100 эпох. Максимальная достигнутая точность (precision) детектирования на 1500 примерах составила 0,98 %, а полнота (recall) – 0,90 %. Максимальная ассурасу (общая точность классификации) составила 0,87 %. Высокое значение точности детектирования может быть объяснено тем, что значительное число объектов на снимках, которые могли бы быть ложно детектированы как ТС, исключается из обработки алгоритмами сокращения области поиска и фильтрацией гипотез.

В табл. 3 приведены данные о каждом слое (количество и размер ядер сверток), а также формулы для расчета на каждом сверточном, субдискретизирующем и полносвязном слоях.

Внедрение нейронов высокого порядка возможно в любой слой СНС: как сверточный, так и полносвязный, и даже субдискретизирующий. Однако внедрение в различные типы слоев будет по-разному вли-

ять на такие характеристики нейронной сети, как точность распознавания объектов и обобщающая способность. Таким образом, и влияние на результат работы сети будет различным. В ходе исследований установили, что оптимальным выбором для внедрения нейронов второго порядка оказались первый и второй сверточные слои. Применение нейронов на третьем сверточном слое не оправдано, так как приводит к увеличению вычислительной сложности без увеличения качества работы нейронной сети.

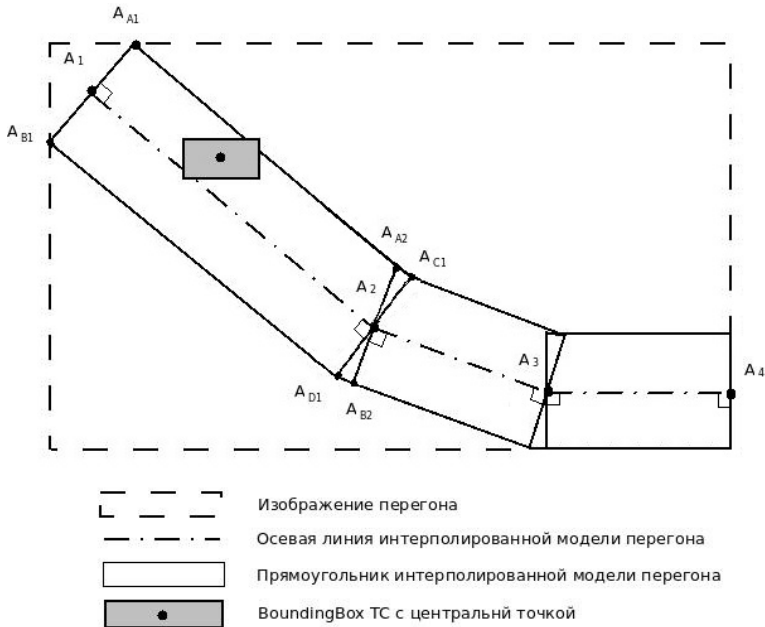
Таблица 3

*Структура используемой сверточной сети*

<i>№ n/n</i>	<i>Слой</i>	<i>Разме- ры яд- ра</i>	<i>Кол-во кана- лов</i>	<i>Формулы формирования сигнала</i>
<i>Вход</i>		Входное изображение 68×68		
<i>1</i>	<i>Сверточный слой C1 (с нейронами 2-ого порядка) на выходе 16 каналов 63x4</i>	5×5	8	$y_j = f\left(\sum_{i=1}^m (w_{ji}(k) y_i(k) + u_{ji}(k) y_i^2(k))\right)$
<i>2</i>	<i>Субдискретизи- рующий слой S1 на выходе 16 каналов</i>	4×4	8	$y_j = f(a_j \max(y_j))$
<i>3</i>	<i>Сверточный слой C2 (с нейронами 2-ого порядка)</i>	5×5	24	$y_j = f\left(\sum_{i=1}^m (w_{ji}(k) y_i(k) + u_{ji}(k) y_i^2(k))\right)$
<i>4</i>	<i>Субдискретизи- рующий слой S2</i>	4×4	24	$y_j = f(a_j \max(y_j))$
<i>5</i>	<i>Сверточный слой C3</i>	3×3	112	$y_j = f\left(\sum_{i=1}^m (w_{ji}(k) y_i(k))\right)$
<i>6</i>	<i>Полносвязный слой F</i>	-	-	$y_j = f\left(\sum_{i=1}^n (w_{ji}(k) y_i(k))\right)$
<i>Выход</i>		4 сигнала от полносвязного слоя		

### Разработка алгоритма определения направления движения ТС

Нейронная сеть, обрабатывая изображение гипотезы, соотносит ее одному из классов ТС. Таким образом, выполняется детектирование и классификация ТС. Однако для оценки показателей транспортного потока, помимо соответствия детектированных ТС перегону, также требуется, чтобы было определено, в каком направлении дороги движется ТС, в случае двустороннего движения на перегоне. Для этого был разработан алгоритм, основанный на местоположении детектированного ТС относительно осевой линии интерполированной модели дорожного полотна. Определяется, на какой половине дороги находится центральная точка BoundingBox детектированного ТС. То есть при рассмотрении интерполированной цифровой модели перегона устанавливают, с какой стороны относительно ломаной цепочки отрезков перегона находится центральная точка ТС (рис. 9).



**Рис. 9. Определение направления дорожного движения путем нахождения положения центральной точки гипотезы относительно осевой линии интерполированной модели перегона**



Для идентификации направления дорожного движения на перегоне было принято следующее обозначение. Направление дорожного движения нумеруется индексом ноль, если для каждой точки, находящейся на дорожной полосе перегона, справедливо следующее соотношение:

$$x > x_0, \quad (5)$$

где

$x$  – абсцисса рассматриваемой точки;

$x_0$  – абсцисса точки основания перпендикуляра, проведенного от рассматриваемой точки к осевой линии интерполированной модели перегона.

Если соотношение не выполнено – направление дорожного движения ТС, находящихся на соответствующей полосе, индексируется единицей.

#### *Алгоритм определения направления дорожного движения по BoundingBox ТС*

1. Вычисление координат центральной точки ТС  $(x_{bb} + \frac{w_{bb}}{2}; y_{bb} + \frac{h_{bb}}{2})$ , где  $(x_{bb}; y_{bb})$  – координаты BoundingBox ТС,  $w_{bb}, h_{bb}$  – ширина и высота BoundingBox ТС.

2. Нахождение перпендикуляра с минимальной длиной к одной из прямых, проведенных от отрезков ломаной рассматриваемого перегона.

3. Определение соотношения координат точки основания перпендикуляра и центральной точки ТС. Если  $x_0 - x < 0$ , то точка находится с одной стороны от ломаной линии; если же  $x_0 - x > 0$ , то с другой.

Для выполнения шага 2 вышеприведенного алгоритма был разработан алгоритм поиска кратчайшего перпендикуляра от точки на плоскости к прямой, проведенной из отрезка ломаной линии. То есть на плоскости задана точка  $S(x, y)$  и ломаная линия, образованная последовательностью точек  $A_k(x_k, y_k), k = \overline{1, q}$ , где  $q$  – общее количество точек на ломаной. Необходимо найти такой перпендикуляр от точки  $S$  к прямой, проведенной из какого-либо отрезка ломаной, который будет иметь наименьшую длину из всех возможных перпендикуляров.

#### *Разработанный алгоритм состоит из следующих шагов:*

1. Создается пустой список перпендикуляров  $L$ .

2. Вычисление координаты точки основания перпендикуляра на прямую, проведенную из отрезка ломаной. Для очередного отрезка,

заданного точками  $A_k(x_k, y_k)$  и  $A_{k+1}(x_{k+1}, y_{k+1})$ , из цепочки перегона вычисляется координата точки основания перпендикуляра на прямую, построенную из отрезка [wikipedia.org/wiki/Перпендикулярность]:

$$x_p = \frac{x_k(y_{k+1}-y_k)^2 + x_{k+1}(x_{k+1}-x_k)^2 + (x_{k+1}-x_k)(y_{k+1}-y_k)(y-y_k)}{(y_{k+1}-y_k)^2 + (x_{k+1}-x_k)^2}; \quad (6)$$

$$y_p = \frac{(x_{k+1}-x_k)(x-x_p)}{(y_{k+1}-y_k)} + y, \quad (7)$$

где

$P_k(x_{pk}, y_{pk})$  – точка основания перпендикуляра к прямой, заданной точками  $A_k(x_k, y_k)$  и  $A_{k+1}(x_{k+1}, y_{k+1})$ ;

$S(x, y)$  – точка, от которой строится перпендикуляр на прямую  $A_k A_{k+1}$ . При этом не обязательно точка  $P_k$  принадлежит отрезку  $A_k A_{k+1}$ .

3. Включение точки основания перпендикуляра в список возможных перпендикуляров. В список перпендикуляров  $L$  добавляются координаты точки основания перпендикуляра  $P_k(x_{pk}, y_{pk})$ :  $L = L \cup P_k$ . Точка  $P_k(x_{pk}, y_{pk})$  принадлежит отрезку  $A_k A_{k+1}$ , если выполнено:

$$x_p \in [\min(x_k, x_{k+1}); \max(x_k, x_{k+1})]. \quad (8)$$

4. Поиск перпендикуляра с наименьшей длиной. Из списка возможных перпендикуляров  $L$  извлекается перпендикуляр с наименьшей длиной:

$$P_{min}(x_{pmin}, y_{pmin}): |P_{min}S| = \min(|P_k S|), k = \overline{1, q}, P_k \in L; \quad (9)$$

$$|P_k S| = \sqrt{(x_{pk} - x)^2 + (y_{pk} - y)^2}, \quad (10)$$

где

$P_{min}(x_{pmin}, y_{pmin})$  – точка основания перпендикуляра с наименьшей длиной,  $\min$  – функция поиска минимума;

$q$  – количество точек в ломаной;

$P_k(x_{pk}, y_{pk})$  – точка основания  $k$ -ого перпендикуляра;

$S(x, y)$  – точка, от которой строятся перпендикуляры.

Результатом работы предложенного авторами алгоритма является найденная точка основания перпендикуляра с наименьшей длиной  $P_{min}(x_{pmin}, y_{pmin})$  и сам перпендикуляр  $P_{min}S$ .

В результате по позиции ТС относительно осевой линии интерполированной модели перегона будет определено направление движения ТС на перегоне.

---

---

## ВЫВОДЫ

Задача детектирования и классификации объектов в транспортном потоке на спутниковых изображениях является важной частью в решении задачи интерпретации данных, поступающих из систем дистанционного зондирования Земли (ДЗЗ). Данные дистанционного зондирования (ДДЗ) Земли, получаемые с орбитальных носителей, являются источником обширной и разнообразной информации о наземных объектах [8-9].

Предложенный метод позволит оценивать состояние дорожного движения и эффективность его организации, выявлять и прогнозировать развитие процессов, влияющих на состояние дорожного движения, контролировать сферу безопасности и организации дорожного движения, значительно чаще одного раза в год, чем указано в документе [1, п. 10].

Увеличение значений параметров плотности дорожного движения и состава транспортного потока влияет на темпы развития повреждений дорожных покрытий, что отражается на доле расходов на ремонт и содержание дорожной сети при осуществлении оценки транспортно-эксплуатационного состояния автомобильной дороги; рост таких параметров оказывает непосредственное воздействие на безопасность дорожного движения. Значения указанных параметров могут быть использованы при своевременном принятии решений по развитию дорожной сети на различных этапах проектирования.

Особо следует отметить, что в условиях стремительно меняющихся режимов дорожного движения в связи с продолжающимся взрывным ростом автомобилизации населения в городах требуется сокращение времени на корректировку управляющих решений ИТС с периодической их актуализацией, а также решение задачи ИТС по осуществлению и поддержке возможности автоматизированного и автоматического взаимодействия транспортных субъектов, что непосредственно оказывает воздействие на эффективность и безопасность дорожного движения [2-3, 9].

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

---

---

**ЛИТЕРАТУРА**

1. *Порядок мониторинга дорожного движения. Утвержден приказом Минтранса России от 18 апреля 2019 г. № 114 // Гарант.ру: сайт. URL: <https://www.garant.ru/products/ipo/prime/doc/72171658/> (дата обращения: 23.03.2023).*
2. *Синергия подходов к совершенствованию интеллектуальных транспортных систем городов в России и Белоруссии: [монография] / [И. Н. Пугачев и др.]; Министерство науки и высшего образования Российской Федерации, ФГБОУ ВО «ТОГУ». – Хабаровск: Издательство ТОГУ, 2020. – 230 с.*
3. *Пугачев И.Н. Система мониторинга на основе спутниковой навигации / И.Н. Пугачев, С.М. Бурков, Г.Я. Маркелов, С.В. Плесовских. – Хабаровск: Изд-во Тихоокеан. гос. ун-та, 2015. – 183 с.*
4. *Правила определения основных параметров дорожного движения и ведения их учета. Утверждены постановлением Правительства РФ от 16 ноября 2018 г. № 1379 // Консорциум «Кодекс»: сайт. URL: <https://docs.cntd.ru/document/551723828> (дата обращения: 23.03.2023).*
5. *Пугачев И.Н. Ускорение алгоритма детектирования транспортных средств на спутниковых снимках с помощью процедуры фильтрации гипотез / И.Н. Пугачев, Г.Я. Маркелов, В.С. Тормозов // Вестник Российского нового университета, серия «Сложные системы: модели, анализ, управление». – 2019. – №. 1. – С. 130-139.*
6. *Пугачев И.Н. Методика подсчета транспортных средств с использованием космических снимков сверхвысокого пространственного разрешения / И.Н. Пугачев, Г.Я. Маркелов, В.С. Тормозов // Вестник ТОГУ. – 2017. – №. 2 (45). – С. 13-20.*
7. *Пугачев И.Н. Обучение и использование сверточной нейронной сети для детектирования и классификации транспортных средств на спутниковых снимках сверхвысокого разрешения / И.Н. Пугачев, Г.Я. Маркелов, В.С. Тормозов // Промышленные АСУ и контроллеры. – 2019. – №. 10. – С. 20-25.*
8. *Пугачев И.Н. Применение модели кластерных сетевых структур в решении задач оптимизации управления движением на базовой сети автотранспортных магистралей / И.Н. Пугачев, С.М. Бурков // Дороги и мосты – 2011. – № 26/2. – С. 11-23.*

9. Пугачев И.Н. Комплексный подход к развитию и повышению эффективности функционирования транспортных систем городов / И.Н. Пугачев // Дороги и мосты. – 2011. – Вып. 25/1. – С. 20-37.

### L I T E R A T U R A

1. Poryadok monitoringa dorozhnogo dvizheniya. Utverzhden prikazom Mintransa Rossii ot 18 aprelya 2019 g. № 114 // Garant.ru: sajt. URL: <https://www.garant.ru/products/ipo/prime/doc/72171658/> (data obrashcheniya: 23.03.2023).
2. Sinergiya podhodov k sovershenstvovaniyu intellektual'nyh transportnyh sistem gorodov v Rossii i Belorussii: [monografiya] / [I. N. Pugachev i dr.]; Ministerstvo nauki i vysshego obrazovaniya Rossijskoj Federacii, FGBOU VO «TOGU». – Habarovsk: Izdatel'stvo TOGU, 2020. – 230 s.
3. Pugachev I.N. Sistema monitoringa na osnove sputnikovoj navigacii / I.N. Pugachev, S.M. Burkov, G.Ya. Markelov, S.V. Plesovskih. – Habarovsk : Izd-vo Tihookean. gos. un-ta, 2015. – 183 s.
4. Pravila opredeleniya osnovnyh parametrov dorozhnogo dvizheniya i vedeniya ih ucheta. Utverzhdeny postanovleniem Pravitel'stva RF ot 16 noyabrya 2018 g. № 1379 // Konsorcium «Kodeks»: sajt. URL: <https://docs.cntd.ru/document/551723828> (data obrashcheniya: 23.03.2023).
5. Pugachev I.N. Uskorenie algoritma detektirovaniya transportnyh sredstv na sputnikovyh snimkah s pomoshch'yu procedury fil'tracii gipotez / I.N. Pugachev, G.Ya. Markelov, V.S. Tormozov // Vestnik Rossijskogo novogo universiteta, seriya «Slozhnye sistemy: modeli, analiz, upravlenie». – 2019. – №. 1. – S. 130-139.
6. Pugachev I.N. Metodika podscheta transportnyh sredstv s ispol'zovaniem kosmicheskikh snimkov sverhvyssokogo prostranstvennogo razresheniya / I.N. Pugachev, G.Ya. Markelov, V.S. Tormozov // Vestnik TOGU. – 2017. – №. 2 (45). – S. 13-20.
7. Pugachev I.N. Obuchenie i ispol'zovanie svertochnoj nejronnoj seti dlya detektirovaniya i klassifikacii transportnyh sredstv na sputnikovyh snimkah sverhvyssokogo razresheniya / I.N. Pugachev, G.Ya. Markelov, V.S. Tormozov // Promyshlennye ASU i kontrolyery. – 2019. – №. 10. – S. 20-25.
8. Pugachev. I.N. Primenenie modeli klasternyh setevyh struktur v reshenii zadach optimizacii upravleniya dvizheniem na bazovoj seti avto-

---

*transportnyh magistralej / I.N. Pugachev, S.M. Burkov // Dorogi i mosty -- 2011. – № 26/2. – S. 11-23.*

9. *Pugachev I.N. Kompleksnyj podhod k razvitiyu i povysheniyu effektivnosti funkcionirovaniya transportnyh sistem gorodov / I.N. Pugachev // Dorogi i mosty. – 2011. – № 25/1. – S. 20-37.*

.....

**DEVELOPMENT OF A NEW METHOD FOR DETECTION  
AND CLASSIFICATION OF VEHICLES ON SATELLITE IMAGES**

*Doctor of Technical Sciences I.N. Pugachev  
(Khabarovsk Federal Research Center of  
the Far Eastern Branch of  
the Russian Academy of Sciences (KhFRC FEB RAS))*

*Ph. D. (Tech.) V.S. Tormozov,  
(Pacific State University)*

*Contact information: ipugachev64@mail.ru;  
007465@pnu.edu.ru*

*Effective traffic management should ensure uniform loading of the transport network at the limit of its capacity, preventing overload of vulnerable areas, as well as predict the development of the transport situation. A method for accelerating the algorithm for detecting vehicles on satellite images is proposed. The approach is based on the application of a hypothesis filtering procedure after a selective search for certain parameters. This reduces the number of hypotheses processed by the recognition algorithm and accelerates the detection algorithm. The considered method will allow to assess traffic state and the effectiveness of its organization, to identify and predict the development of processes affecting traffic state, to control the sphere of traffic safety and engineering.*

**Key words:** *road traffic safety, traffic flow control system, detection, pattern recognition, selective search, satellite images, computer vision.*

---

Рецензенты: Заместитель руководителя Департамента развития интеллектуальных транспортных систем и проектирования И.А. Евстигнеев; канд. техн. наук Б.Б. Анохин (ФАУ «РОСДОРНИИ»).

Статья поступила в редакцию: 23.03.2023 г.