

Исследование интенсивности транспортных потоков методами машинного обучения для интеллектуальных транспортных систем



Н. Г. Шешера,
канд. техн. наук, старший научный сотрудник Дальневосточного государственного университета путей сообщения (ДВГУПС),



И. Н. Пугачев,
д-р техн. наук, заместитель директора по научной работе Хабаровского федерального исследовательского центра Дальневосточного отделения РАН, профессор кафедры изысканий и проектирования железных и автомобильных дорог ДВГУПС,



Д. Е. Григоров,
начальник кабинета специальных дисциплин кафедры информационного и технического обеспечения ОВД Дальневосточно-го юридического института МВД России имени И. Ф. Шилова

Эффективность интеллектуальных транспортных систем в городских агломерациях зависит от возможностей их программно-аппаратных комплексов по анализу интенсивности транспортных потоков. Сегодня данный параметр считают с использованием нейронных сетей по видеопотоку и моделируют для прогноза. Однако такую модель нельзя считать универсальной.

Мировой опыт создания интеллектуальных транспортных систем (ИТС) подтвердил их высокую эффективность в повышении безопасности дорожного движения. В качестве примера можно привести автоматизированную систему управления дорожным движением, используемую на автобане A9 в ФРГ. По отчетам Дирекции автобанов Южной Баварии внедрение автоматизированной системы управления дорожным движением на данной трассе позволило снизить количество ДТП на 35,9%, в том числе с пострадавшими — на 34,4%.

Согласно Транспортной стратегии РФ на период до 2030 г. с прогнозом на период до 2035 г. в рамках проектов «Общесистемные меры развития дорожного хозяйства» и «Безопасные качественные дороги» в российских регионах продолжаются мероприятия по внедрению ИТС¹.

Сложная система взаимодействия транспортных потоков в городских агломерациях чувствительна к изменению параметров ВАДС², поломке объекта управления, ДТП, ремонту дороги и т. п. Создаются затруднения в движении, может быть парализована вся транс-

портная сеть. В таких случаях концепция интеллектуальных транспортных систем предусматривает оперативное моделирование транспортного распределения с учетом сложившейся обстановки с последующим изменением режимов объектов управления. Существуют примеры использования для этих целей нейросетевых технологий.

На сегодняшний день в ИТС нейронные сети применяют для сбора данных с целью прогноза опасности участка и интенсивности транспортного потока. Аналитические комплексы могут прогнозировать изменение его интенсивности с учетом временных параметров и погодных условий. Это происходит за счет предварительного моделирования с использованием машинного обучения. Но данная модель не применима на другом участке дороги, где ее придется переобучать.

Соответственно центральный аппарат управления ИТС должен содержать множество предиктивных моделей изменения интенсивности транспортных потоков для каждого участка улично-дорожной сети (УДС) городской агломерации, что нагружает вычислительный комплекс и влияет на качество и время обработки информации.

Гипотеза работы заключается в том, что за счет расширения перечня характеристик условий эксплуатации автомобилей, влияющих на интенсивность транспортных потоков, можно создать универсальную модель прогноза. Дан-

¹ Транспортная стратегия Российской Федерации до 2030 г. с прогнозом на период до 2035 г. Утв. распоряжением Правительства РФ от 27.11.2021 № 3363р.

² ВАДС (водитель, автомобиль, дорога, среда) — сложная целостная динамическая система, где каждый из элементов находится в определенных отношениях и связях друг с другом.

ное решение позволит контролировать ключевые участки УДС, в том числе не оборудованные средствами фиксации исследуемого признака.

Подготовка данных

Для анализа зависимостей использовалось большое количество параметров геометрических элементов дорог, характеристик движения, погодных и природных условий, которые теоретически могут влиять на зависимый признак. Данные об интенсивности транспортных потоков собраны с использованием программно-аппаратных комплексов системы «INTEGRO-КДД», которые в круглосуточном режиме ведут подсчет автомобилей на 107 рубежах контроля г. Хабаровска [1].

С целью накопления информации о погодных условиях использовались открытые веб-ресурсы OpenWeatherMap и Gismeteo, так как они приспособлены для работы с данными в режиме разработчика с перспективой циклического обращения к ним [1, 2]. Разработана программа по автоматизированному сбору данных в широком диапазоне параметров. Активную помощь в реализации проекта оказал Хабаровский центр по гидрометеорологии и мониторингу окружающей среды, предоставив данные о погоде со станции Хабаровск с 2016 по 2021 гг.

Такие показатели улично-дорожной сети, как длина участка кривой, радиус, продольный уклон и другие геометрические элементы дорог, измерялись полевым путем или с использованием программы «Google Планета Земля» [3, 4].

Для проверки влияния учитываемых независимых признаков на зависимые проведен корреляционный анализ с учетом различных комбинаций подсистем системы ВАДС. Данные сгруппированы в интервалы.

С целью определения эффективных широт интервалов решено провести ранговую корреляцию Спирмена. Каждый интервал — это количество наблюдаемых случаев в нем, соответственно, обычным корреляционным анализом оценить значимость переменной было бы необъективно. С использованием ранговой системы в одном интервале (например, 0...200 — ранг 1, 200...400 — ранг 2, 400...600 — ранг 3 и т. д.) эта проблема решается [5].

Определены эффективные широты интервалов для количественных признаков. Широты интервалов геоме-

трических элементов дорог принятые в соответствии с таблицей коэффициентов аварийности В. Ф. Бабкова¹, а для погодных условий определены следующие: интенсивность транспортного потока N — 250 авт./ч; температура воздуха t_b — 5 °C; температура почвы t_n — 5 °C; температура точки росы DP — 5 °C; парциальное давление водяного пара p_s — 5 Па; относительная влажность воздуха ϕ — 50%; дефицит насыщения d — 5 г/м³; атмосферное давление на уровне станции Рс — 30 гПа; атмосферное давление на уровне моря P_m — 45 гПа; скорость ветра — 2 м/с; осадки — 2 мм.

Такие показатели, как видимость-шифр (VV), погода-шифр (ww), направление ветра, время суток и день недели, являются качественными второстепенными независимыми признаками. Они необходимы для изменения режимов комбинации и сортировки основных независимых переменных. При дальнейшем анализе с использованием нейронной сети незначительные показатели данных признаков будут помечаться программой соответствующими коэффициентами или исключаться.

Исследование методов машинного обучения

Закономерности взаимодействия элементов системы ВАДС сложно описать, опираясь на собственную интуицию, поэтому существуют примеры использования инструментов искусственного интеллекта.

В результате исследования опыта отечественных и зарубежных специалистов в области организации и безопасности дорожного движения, применявших для своих целей инструменты машинного обучения, выделены два методологических направления: методы глубокого обучения [6–8]; ансамблевые методы машинного обучения [9, 10].

В России для реализации интеллектуальных модулей транспортных систем используются алгоритмы глубокого обучения. Решено применить данный подход для анализа интенсивности транспортных потоков и повышения эффективности ИТС при прогнозе травматизма в результате ДТП. Подобную задачу решали в Оренбургском государственном университете исследовате-

ли И. П. Болодурина, Л. М. Анциферова и Л. С. Гришина. Авторы ограничились прогнозом интенсивности только на перекрестках с использованием нейронных сетей [6]. Для повышения качества оценки зависимого признака ими предложено использовать вместо глубокого обучения ансамблевые методы. Исходя из этого для определения интенсивности транспортного потока рассмотрены оба подхода.

Изначально структура нейронной сети строилась на анализе данных без предварительной обработки и валидации. Тестирование модели после обучения показало неэффективность прогноза. Это связано с большим количеством входящих нейронов, поэтому принято решение сгруппировать количественные признаки с учетом разработанных широт.

Для исследования влияния геометрических элементов дорог, погодных и природных условий на интенсивность транспортного потока собрано и сгруппировано 562 612 ч с различными характеристиками со 107 рубежами контроля автомобильного транспорта. Предварительная обработка всего массива данных незначительно повысила качество модели влияния независимых признаков на зависимый, точность составила 51%.

Объясняется это недостаточным перечнем анализируемых факторов, принято решение каждый рубеж анализировать отдельно с перспективой создания не одной, а 107 моделей для прогнозирования. Таким образом, исключено влияние неучтенных статических независимых переменных.

Значения очищены от аномалий, которые связаны со сбоями ситуациями УДС и фиксирующей аппаратурой. Для этой цели лучше всего подошел метод изолированного леса, так как показатель интенсивности транспортного потока не имеет ярко выраженного нормального распределения.

Как показано в табл. 1, при улучшении точности прогноза (*test acc*) увеличивается и ошибка (*test loss*).

В простых задачах классификации метод глубокого обучения показал себя как надежный, точный и адаптивный инструмент. Однако в данной работе ставилась задача создать универсальную модель за счет большого количества признаков. К сожалению, нейронная сеть оказалась неэффективна, прогнозистические способности модели получились неудовлетворительными из-за

¹ ОДМ 218.4.005-2010. Отраслевой дорожный методический документ. Рекомендации по обеспечению безопасности движения на автомобильных дорогах (издан на основании Распоряжения Росавтодора от 12.01.2011 № 13-р).

Таблица 1. Фрагмент данных оценки моделей методами *test loss* и *test acc* до и после исключения аномалий из показателя интенсивности транспортного потока

Рубеж	С аномалиями		Без аномалий		Рубеж	С аномалиями		Без аномалий	
	<i>test loss</i>	<i>test acc</i>	<i>test loss</i>	<i>test acc</i>		<i>test loss</i>	<i>test acc</i>	<i>test loss</i>	<i>test acc</i>
1011	0,21	0,44	0,36	0,69	1111	0,42	0,24	0,74	0,2
1021	0,26	0,38	0,3	0,67	1121	0,25	0,35	0,33	0,65
1031	0,25	0,31	0,62	0,52	1131	0,23	0,4	0,32	0,62
111	0,52	0,26	0,89	0,43	1141	0,25	0,47	0,4	0,6

большого количества входных и выходных данных. В результате исчерпывающего перечня исследований можно сделать вывод о том, что нейронные сети не подходят для прогноза интенсивности транспортного потока от рассматриваемых в работе признаков.

С целью повышения точности прогноза интенсивности транспортного потока от параметров геометрических элементов дорог, характеристик движения, погодных и природных условий решено провести дополнительные исследования методов машинного обучения.

В результате анализа ансамблевых методов машинного обучения в работе [9] доказано, что самую высокую эффективность для решения задач безопасности дорожного движения имеет метод случайного леса. Принцип работы метода заключается в создании множества деревьев решений, обучаемых на различных случайных подмножествах данных и с использованием различных наборов признаков. При классификации каждое дерево в случайном лесу принимает решение на основе голосования большинства классов, присваивая класс с наибольшим количеством голосов.

Опираясь на опыт исследователей, разработаны модули обучения и прогноза интенсивности транспортного потока с применением алгоритмов машинного обучения (метода случайного леса), обучена модель. Блок-схемы алгоритмов обучения и прогноза приведены на рис. 1.

Алгоритм построения случайного леса, состоящего из N деревьев, для каждого $n = 1, \dots, N$ выглядит следующим образом: генерируется выборка x_n с помощью бутстрэпа (процедура многократного извлечения подвыборок из эмпирического распределения); строится решающее дерево b_n по выборке x_n :

- по заданному критерию выбирается лучший признак, выполняется разбиение в дереве по нему и так до исчерпания выборки;

Модуль обучения

```

graph TD
    A([Начало]) --> B[Инициализация зависимостей]
    B --> C[Чтение данных]
    C --> D[Обработка неинформативных данных, в том числе зависимого признака]
    D --> E[Выбор необходимых значений для обучения]
    E --> F([Конец])
  
```

Модуль прогноза

```

graph TD
    A([Начало]) --> B[Инициализация зависимостей]
    B --> C[Загрузка модели]
    C --> D[Чтение данных]
    D --> E[Обработка неинформативных данных, в том числе зависимого признака]
    E --> F[Прогноз]
    F --> G([Конец])
  
```

- дерево строится пока в каждом листе не более n_{\min} объектов или пока не будет достигнута определенная высота дерева;

- при каждом разбиении сначала выбирается m случайных признаков из n исходных, и оптимальное разделение выборки определяется только среди них.

В задачах классификации используют: $m=\sqrt{n}$, где n — число признаков.

Итоговый классификатор выбирается «голосованием по большинству», рассчитывается по формуле

$$a(x) = \frac{1}{N} \sum_{i=1}^N b_i(x),$$

где N — количество деревьев; i — счетчик для деревьев; b — решающее дерево; x — сгенерированная выборка.

Чем выше в среднем признак в дереве решений, тем он важнее в данной задаче классификации. Критерием оценки качества расщепления вершины дерева использован коэффициент Джини:

$$Gini(T) = 1 - \sum_{i=1}^n p_i^2,$$

где T — текущий узел; p_i — вероятность класса i в узле T ; n — количество классов.

Перед обучением особое внимание уделялось предварительной обработке данных, которая включала комплекс мероприятий для заполнения пустых значений. С целью исключения ошибок, связанных с человеческим фактором, автоматизированным способом проведена предпрограммная обработка.

Выбранный метод машинного обучения не нуждается в нормализации значений независимых переменных, как необходимо было сделать при обработке их в нейронной сети. В то же время прогнозирование строится на основе классификации, поэтому зависимая переменная разбита на группы. Приняты следующие группы интенсивностей, авт./ч:

1 группа (0–250);	9 группа (2001–2250);	17 группа (4001–4250);
2 группа (251–500);	10 группа (2251–2500);	18 группа (4251–4500);
3 группа (501–750);	11 группа (2501–2750);	19 группа (4501–4750);
4 группа (751–1000);	12 группа (2751–3000);	20 группа (4751–5000);
5 группа (1001–1250);	13 группа (3001–3250);	21 группа (5001–5250);
6 группа (1251–1500);	14 группа (3251–3500);	22 группа (5251–5500);
7 группа (1501–1750);	15 группа (3501–3750);	23 группа (5501–5750);
8 группа (1751–2000);	16 группа (3751–4000);	

Во время обучения модели случайного леса программа анализировала обучающие данные и создала набор параллельно работающих деревьев решений. Эти деревья обучились на различных подмножествах с использованием под-

Рис. 1. Блок-схемы обучения и прогноза модели методом случайного леса

Информационные технологии

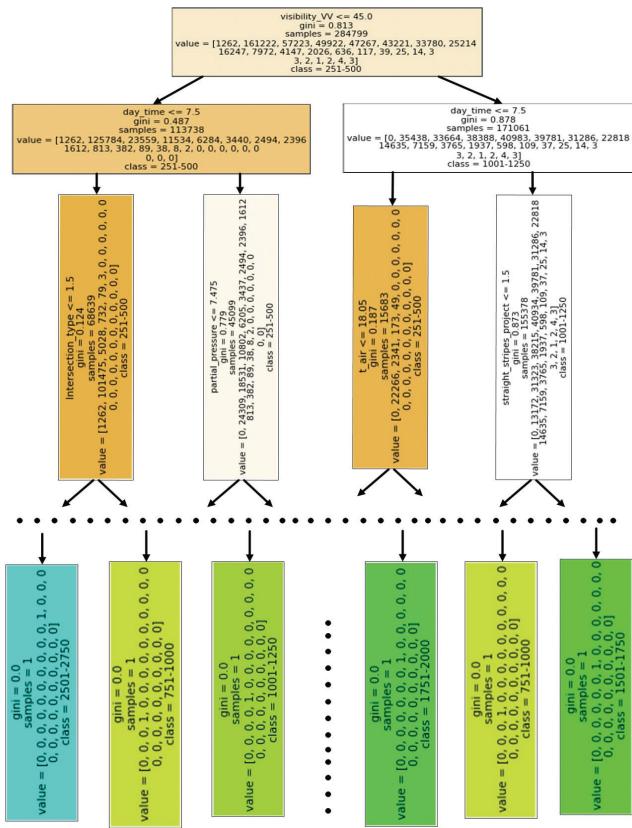


Рис. 2. Фрагмент дерева решений в лесу для прогноза интенсивности транспортного потока: gini – оценка качества расщепления узла; samples – количество образцов после разделения; value – количество наблюдаемых классов в выборке после разделения; class – класс с самой высокой встречаемостью по заданным условиям

хода случайного выбора подмножества признаков. Построен ансамбль из 500 деревьев решений (рис. 2), которые работают вместе для принятия классификационных решений.

Для определения степени влияния независимых переменных на зависимую проведена оценка их важности при перестановке:

$$i_j = s - \frac{1}{K} \sum_{k=1}^K S_{k,j},$$

где s – эталонная оценка; k – повторение в $1, \dots, K$; j – признак из колонки.

Путем исключения незначительных независимых признаков достигнута максимальная эффективность модели. Accuracy составил 71,61, коэффициент детерминации R² – 0,897. Это говорит о том, что в 71,6 % модель точно спрогнозировала класс интенсивности транспортного потока при различных днях недели, месяцах, показателях времени суток, геометрических элементов дорог, погодных и природных условий.

Итоговые независимые признаки и их степени влияния приведены на рис. 3. Влияние признака определяется в диапазоне от 0 до 1, где 0 – это отсутствие влияния, а 1 – это 100 % влияния.

В качестве дополнительной проверки точности модели создана матрица неточностей, которая применяется в задачах классификации. В ней представлена информация о том, какие группы модель предсказала правильно, а какие нет на тестовых данных (рис. 4).

Матрица неточностей представляет собой квадратную матрицу, где каждый элемент (i, j) матрицы – это количество объ-

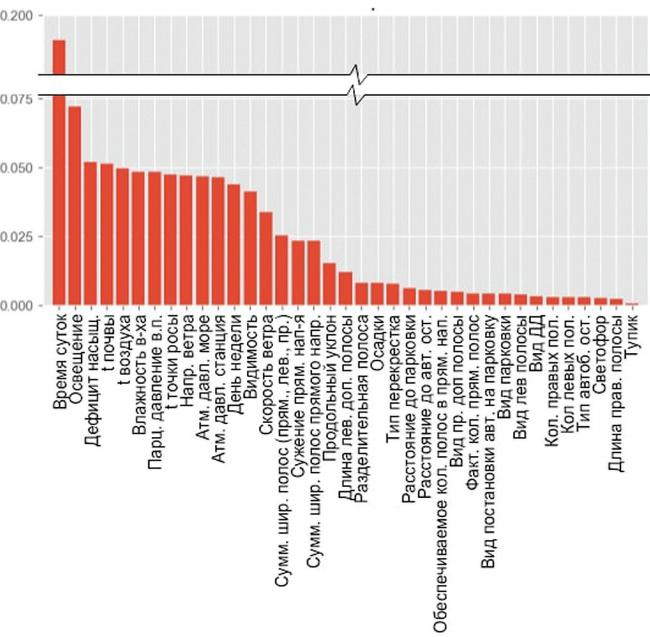


Рис. 3. Веса независимых признаков модели прогноза интенсивности транспортных потоков

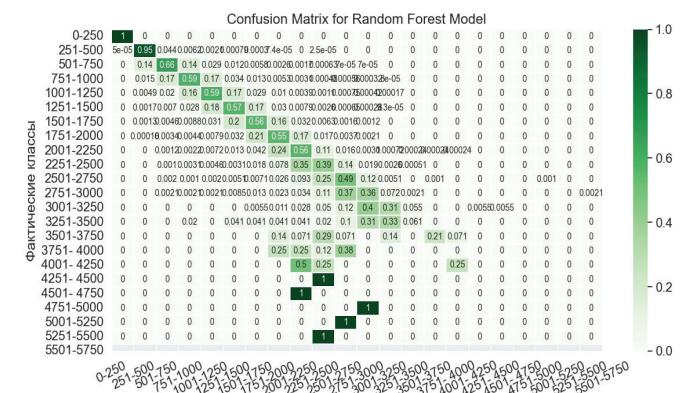


Рис. 4. Матрица неточностей при исследовании интенсивности транспортного потока

ектов, которые на самом деле принадлежат классу i , но были предсказаны как класс j . Таким образом, матрица неточностей дает информацию о верно классифицированных и ошибочно классифицированных объектах для каждого класса.

С 17-й группы (4001–4250 авт./ч) модель значительно теряет свою точность из-за малого количества встречаемости групп с высокой часовой интенсивностью. Это подтверждается и результатами Receiver Operating Characteristic анализа для каждой группы:

1 группа, AUC = 0,99;	9 группа, AUC = 0,98;	17 группа, AUC = 0,5;
2 группа, AUC = 0,95;	10 группа, AUC = 0,98;	18 группа, AUC = nan;
3 группа, AUC = 0,94;	11 группа, AUC = 0,98;	19 группа, AUC = nan;
4 группа, AUC = 0,94;	12 группа, AUC = 0,97;	20 группа, AUC = nan;
5 группа, AUC = 0,94;	13 группа, AUC = 0,94;	21 группа, AUC = nan;
6 группа, AUC = 0,95;	14 группа, AUC = 0,89;	22 группа, AUC = nan;
7 группа, AUC = 0,96;	15 группа, AUC = 0,87;	23 группа, AUC = nan;
8 группа, AUC = 0,97;	16 группа, AUC = 0,87;	

Для подтверждения точности модели спрогнозирована интенсивность транспортного потока на ранее заготовленных данных, которые не участвовали в обучении. Результаты приведены в табл. 2.

Таблица 2. Оценка точности прогноза на тестовых данных

Прогноз			Фактическая интенсивность	Прогноз			Фактическая интенсивность
ID	Класс	Интервал		ID	Класс	Интервал	
0	1	0–250	79	15	1	0–250	87
1	1	0–250	39	16	1	0–250	57
2	1	0–250	21	17	5	1001–1250	1539
3	6	1251–1500	1393	18	5	1001–1250	1876
4	6	1251–1500	1426	19	5	1001–1250	893
5	6	1251–1500	1398	20	5	1001–1250	219
6	6	1251–1500	1551	21	1	0–250	31
7	6	1251–1500	1637	22	1	0–250	25
8	4	751–1000	785	23	1	0–250	62
9	2	251–500	452	24	2	251–500	136
10	1	0–250	66	25	4	751–1000	722
11	1	0–250	49	26	4	751–1000	1068
12	1	0–250	16	27	5	1001–1250	1125
13	2	251–500	229	28	4	751–1000	936
14	1	0–250	160	29	3	501–750	620



Рис. 5. Сравнительный анализ прогноза интервалов интенсивности с фактическими значениями

Если сравнивать значения фактических показателей интенсивности при определенных дорожных, погодных и природных условиях в различные периоды времени с прогнозом (табл. 3), можно сделать вывод о правильности в оценке точности accuracy, которая равна 71,6. Из 30 случаев модель ошиблась только в 9 — это 30% от всей тестовой выборки. Но это не значит, что неточные данные прогноза не информативны. С целью дополнительного сравнительного исследования построен график спрогнозированных интервалов и фактической интенсивности транспортного потока (рис. 5).

На рис. 5 видно, что выпадающие из прогноза 30% данных находятся около значений интервалов, соответственно, ошибка невелика.

Данные для обучения охватывают все периоды года с подробной детализацией и объективно характеризуют различия между временем суток, днями и месяцами вследствие изменения температурных режимов, длительности



Рис. 6. Исследование качества прогностической модели с учетом сезонных изменений

светового дня, видов осадков и т. п. В зимнее время интенсивность транспортного потока ниже, чем в летнее и для проверки точности модели с учетом сезонных изменений проведен эксперимент. В результате расчета выяснилось, что в г. Хабаровске по данным с 2018 по 2021 гг. самая высокая среднемесячная интенсивность зафиксирована в июле, а самая низкая — в январе (рис. 6).

Из глобального массива данных сформирована выборка значений интенсивности за январь и июль 2021 г. по 30 временным интервалам для каждого месяца и соответствующие им независимые переменные. Выполнен прогноз, результаты которого представлены на рис. 6.

Несмотря на значительные различия в условиях эксплуатации транспортных сооружений, модель показала хорошую прогностическую точность. В январе она составила 70%, а в июле — 73%. Модель апробирована на УДС не только г. Хабаровска, но и ряда городов других регионов РФ, в частности, в г. Петрозаводске (Республика Карелия).

Данные об интенсивности транспортных средств собраны с помощью анализа непрерывного видеопотока с публичной видеокамеры на основе алгоритма распознавания движущихся объектов YOLOv5 на базе AI-фреймворка PyTorch (рис. 7). Информация о параметрах транспортных сооружений получена в программе «Google Планета Земля», о погодных условиях — с открытых метеорологических ресурсов.

Собранные данные подготовлены в соответствии с правилами метода анализа интенсивности транспортного потока. Используя обученную модель, выполнен прогноз. При сопоставлении реальных значений интенсивности с прогнозом определена точность в 72%. Результаты приведены в табл. 3.

Результатами ошибок могут служить неучтенные факторы, которые требуют дальнейшего исследования. Тем не менее модель можно считать достаточно достоверной для прогноза интенсивности транспортного потока от временных признаков, дорожных, погодных и природных условий.

Заключение

Нейронные сети показывают лучшие результаты при работе с однородными данными, например, обработке изображений, разбивая графическую информацию на типизиро-

Информационные технологии

Таблица 3. Оценка точности прогноза интенсивности на пересечении проезжих частей ул. Ленина и ул. Андропова г. Петрозаводска

Интенсивность		Оценка точности	Интенсивность		Оценка точности	Интенсивность		Оценка точности
Прогноз	Факт		Прогноз	Факт		Прогноз	Факт	
1	74	Точно	2	686	Не точно	1	195	Точно
1	15	Точно	2	530	Не точно	1	110	Точно
1	72	Точно	2	257	Точно	1	259	Не точно
1	34	Точно	3	442	Не точно	1	129	Точно
1	2	Точно	1	393	Не точно	1	32	Точно
1	49	Точно	1	226	Точно	1	158	Точно
3	513	Точно	2	476	Точно	1	105	Точно
6	579	Не точно	1	294	Не точно	1	21	Точно
2	697	Не точно	1	131	Точно	1	89	Точно
2	350	Точно	2	382	Точно			



Рис. 7. Кадр публичной видеокамеры пересечения проезжих частей ул. Ленина и ул. Андропова г. Петрозаводска, на котором выполняется алгоритм распознавания движущихся объектов

ванную структуру и анализируя однородную последовательность пикселей.

На большом количестве разнородных данных модель демонстрирует худшие результаты из-за неявных взаимосвязей. При исследовании интенсивности транспортного потока с использованием нейронных сетей имели успех только те ученые, которые брали ограниченный перечень данных (пример, время и день недели). Такие модели применимы на конкретном участке, а при более широком диапазоне входящих данных наблюдается проблема переобучаемости — в новых ситуациях прогнозы становятся все хуже и хуже.

Методом случайного леса обучена модель прогноза интенсивности транспортного потока на широком диапазоне данных, что сделало ее универсальной. Точность составила 71,6 %. Качество модели прогноза интенсивности транспортного потока с использованием случайного леса подтверждено на примере другой городской агломерации. Т

Источники

- Пугачев И. Н., Скрипко П. Б., Шешера Н. Г. Программный подход к комплексному сбору и подготовки данных об интенсивности движения транспортных средств, погодных условий и естественной освещенности в часовых интервалах // Т-Comm: Телекоммуникации и транспорт. 2023. Т. 17. № 10. С. 43–51.
 - Пугачев И. Н., Шешера Н. Г., Григорьев Д. Е. Использование инструментов современных библиотек Python по работе с географическими координатами для решения задач безопасности дорожного движения // Транспорт Азиатско-Тихоокеанского региона. 2024. № 3(40). С. 60–66.
 - Жук А. Ю., Саблин С. Ю., Скрыпников А. В. и др. Исследование математической модели рельефа местности при проектировании автомобильных дорог // Системы. Методы. Технологии. 2021. № 2 (50). С. 88–93.
 - Голов Е. В., Сорокина Е. В., Евтухов С. С. Проблемные вопросы использования спутниковой навига-
- ции при оценке состояния факторов «Дорога» и «Среда» в системе ВАДС // Вестник гражданских инженеров. 2022. № 4 (93). С. 141–150.
- Пугачев И. Н., Шешера Н. Г., Григорьев Д. Е. Определение эффективных широт интервалов влияния температурных режимов на интенсивность транспортного потока с использованием ранговой корреляции Спирмена // Т-Comm: Телекоммуникации и транспорт. 2024. Т. 18. № 3. С. 34–40.
 - Болодурина И. П., Анциферова Л. М., Гришина Л. С. Интеллектуальная модель прогнозирования интенсивности движения транспортных средств на перекрестке // Интеллект. Инновации. Инвестиции. 2022. № 6. С. 69–78.
 - Зацерковный А. В., Нурминский Е. А. Нейросетевой анализ транспортных потоков городских агломераций на основе данных публичных камер видеообзора // Компьютерные исследования и моделирование. 2021. Т. 13. № 2. С. 305–318.
 - Mazloumi E., Rose G., Currie G., Moridpour S. Prediction intervals to account for uncertainties in neural network predictions: methodology and application in bus travel time prediction // Eng. Appl. Artif. Intell. 2011. № 24(3). Рр. 534–542.
 - Донченко Д. С., Садовникова Н. П., Парыгин Д. С. Прогнозирование степени тяжести последствий ДТП с использованием методов машинного обучения // Вестник Воронежского института высоких технологий. 2019. № 13(4).
 - Habib M., Bashir B., Alsalman A., Bachir H. Evaluating the accuracy and effectiveness of machine learning methods for rapidly determining the safety factor of road embankments // Multidiscipline Modeling in Materials and Structures. 2023. Vol. 19. № 5. Рр. 966–983.