



## Анализ загруженности трафика на главных улицах электронного города с применением индекса перегрузки и искусственной нейронной сети (на примере города Хамедан)

<sup>1</sup>М.М. Ширмохаммади, ORCID: 0000-0001-8858-3770 <mmshirmohammadi@iauh.ac.ir>

<sup>2</sup>М. Эсмаилпур, ORCID: 0000-0002-2475-518X <esmaeilpour@iauh.ac.ir>

<sup>1</sup>Аракский филиал Исламского университета Азад,  
Иран, Арак, 3-й км дороги Хомейна, площадь Имама Хомейни

<sup>2</sup>Хамеданский филиал Исламского университета Азад,  
Иран, Хамедан, бул. Мусиванд, Мадани Таун

**Аннотация.** Заторы на дорогах являются серьезной проблемой для электронных городов, и для решения этой проблемы необходимо анализировать пробки в городской дорожной сети. В этой статье изучается показатель эффективности транспортных средств для оценки условий дорожных сетей. В нашем исследовании исследуется плотность трафика главной дорожной сети города Хамедан на основе данных о скорости, собранных системой управления движением Хамедана. На основе этого анализа были определены индекс трафика и пиковые часы трафика. Кроме того, с использованием нейронной сети и генетического алгоритма была определена предсказуемая связь между скоростью транспортных средств и загруженностью трафика. В работе использовались данные Центра управления движением Хамедана о скорости движения транспортных средств в густонаселенных районах.

**Ключевые слова:** пробки на дорогах; эффективность скорости; городские дорожные сети; управление и контроль трафика; нейронная сеть; генетический алгоритм

**Для цитирования:** Ширмохаммади М.М., Эсмаилпур М. Анализ загруженности трафика на главных улицах электронного города с применением индекса перегрузки и искусственной нейронной сети (на примере города Хамедан). Труды ИСП РАН, том 32, вып. 3, 2020 г., стр. 131-146. DOI: 10.15514/ISPRAS-2020-32(3)-12.

## Analysis of Traffic Congestion in Main Streets of Electronic city using Traffic Congestion Index and Artificial Neural Network (Case Study: Hamedan City)

<sup>1</sup>M.M. Shirmohammadi, ORCID: 0000-0001-8858-3770 <mmshirmohammadi@iauh.ac.ir>

<sup>2</sup>M. Esmaeilpour, ORCID: 0000-0002-2475-518X <esmaeilpour@iauh.ac.ir>

<sup>1</sup>Islamic Azad University Arak Branch,  
3rd km of Khomein road, Imam Khomeini Square, Arak, Iran

<sup>2</sup>Islamic Azad University Hamedan Branch,  
Mousivand Blvd., Madani Town, Hamedan, Iran

**Abstract.** Smart cities are a kind of umbrellas of different technologies for responding to the problem of increasing urban population. The priority of intelligent electronic cities is a strategy to collecting information about the city and its smart use to improve the provided services to citizens or to create new services. These smart cities have weather forecast, urban monitoring, pollution monitoring and various applications. Traffic is

a major challenge for electronic cities and coping with it requires analyzing traffic congestion in the city road network. The data transmission with wireless signals in smart cities is one of the challenges because construction of high buildings and barriers reduces the power and quality of the signal. Widespread use of wireless signals and equipment may lead to interference and reduce service quality. Therefore, in order to solve the traffic problem, it is necessary to achieve traffic congestion levels by collecting information, especially with wireless signals so that it can be programmed to control and manage traffic. In this paper, the performance index of vehicle speed was estimated to evaluate the conditions of road networks. This study analyzes the traffic density for the main network of Hamedan communication routes based on the collected data of Speed performance of Hamedan traffic control system. According to this analysis, the congestion index and traffic peak hours were determined. Also the relationship between vehicle speed and traffic congestion was predicted by neural network and the genetic algorithm. In this study areas of traffic were identified using Hamedan Traffic Control Center according with the speed of vehicles.

**Keywords:** Traffic Congestion; Speed Performance; Urban Road Network; Traffic Management and Control

**For citation:** Shirmohammadi M.M., Esmaeilpour M. The Traffic Congestion Analysis using Traffic Congestion Index and Artificial Neural Network in Main Streets of Electronic city (Case Study: Hamedan City). Trudy ISP RAN/Proc. ISP RAS, vol. 32, issue 3, 2020. pp. 131-146 (in Russian). DOI: 10.15514/ISPRAS-2020-32(3)-12

## 1. Введение

Основой электронных интеллектуальных городов являются различные технологии, помогающие решить проблему роста городского населения. Приоритетным направлением является сбор информации о городе и его интеллектуальном использовании для улучшения услуг, предоставляемых гражданам, или для создания новых услуг [1]. В интеллектуальных городах имеются приложения для прогноза погоды, мониторинга градостроительства, мониторинга загрязнений и других разнообразных применений [2].

Проблемой больших городов являются пробки, и одним из решений этой проблемы является повышение уровня интеллектуальности города. Владение точной информацией о ситуации в городе может помочь принять важные решения в городском управлении. В масштабе города могут использоваться различные датчики, объединенные в беспроводную сенсорную сеть и собирающие ценную информацию [3].

Однако беспроводная передача данных в интеллектуальных городах затруднительна, потому что наличие высоких зданий приводит к снижению качества сигналов [4]. Широкое использование беспроводного оборудования может привести к помехам и снижению качества обслуживания [5]. Поэтому, чтобы решить проблему перегрузки трафика, требуется собирать информацию (с использованием беспроводных сетей), чтобы на ее основе обеспечить контроль трафика и управление им.

В настоящее время нет фиксированных и стабильных оценочных инструментов для оценки состояния трафика; фактически, в разных регионах используются различные меры и оценки, основанные на конкретных приложениях и потребностях. Однако можно вычислить среднее время пиковой нагрузки трафика путем определения индекса оценки загруженности.

Во втором разделе статьи приведен обзор работ, связанных с электронными городами. В третьем разделе обсуждается предлагаемый метод для расчета индексов. В четвертом разделе описывается применение этого метода в условиях города Хамедан, и в последнем, пятом разделе представлено заключение.

## 2. Состояние области

Интеллектуальные города разного масштаба были созданы во многих крупных городах мира различными способами для конкретных применений, включая управление трафиком. Один из таких проектов был реализован в Сингапуре. Этот проект основан на облачных вычислениях, он фокусируется на интеллектуальных транспортных задачах, имитирует и

оценивает структуру потока данных, характеризующих трафик. Для оценки ситуации с дорожным движением в этом проекте были выделены параметры дорожных сетей, были изучены сценарии трафика и разработаны алгоритмы извлечения данных [6].

В Азии одним из самых развитых интеллектуальных городов является Сонгдо (Южная Корея). Это полностью цифровой город, в котором все информационные системы взаимосвязаны, и практически все объекты привязаны к информационной системе [7]. Этот проект предназначен для продвижения интересов частного бизнеса, не обращая внимания на потребности сообщества рядовых граждан [8].

В одном из успешных проектов по созданию интеллектуального города в г. Сантандер в Испании использовались беспроводные датчики в среде интернета для измерения концентрации угарного газа, интенсивности света, шума, температуры и движения транспортных средств [9].

Барселона [10] является ещё одним примером успешного интеллектуального города, который известен как самый умный город в мире. В Барселоне имеется мощная платформа с комплексной инфраструктурой. Эта технология обеспечивает связность элементов города и позволяет им легко взаимодействовать друг с другом, а также управлять ими с помощью электронных устройств. Интеллектуальная модель Барселоны предусматривает 12 регионов с экологическими проектами, ICT, мобильностью, водой, энергией, управлением отходами, природой, территорией и сооружениями, открытым пространством и услугами.

Цзя (Shunping Jia) и др. получили всестороннюю оценку моделей городского трафика на основе средней скорости движения транспортных средств с учетом характеристик простоя в движении и пропускной способности дорожной сети [11]. Чжу (Fuling Zhu) исследовал систему оценки индекса загруженности городского транспорта и распределение скорости автотранспортного средства с использованием смешанной модели Гаусса для характеристик плотности [12].

Кирога (Cesar A. Quiroga) использовал время нахождения в пути для измерения эффективности транспортной сети. В своей работе он обсуждает методы сбора данных о времени поездки и скорости [13].

Роберт (R. Robert) и др. обсудили понятия времени нахождения в пути и длительности поездки и изучили влияние различных показателей на качество загруженности, а также предложили метод классификации перегрузок на основе времени поездки с точки зрения путешественников. В их работе также отмечается, что сложность и динамический характер трафика являются проблемой, которую трудно решить с использованием только одного оценочного индекса. В результате различных исследований трафик стали оценивать на основе нескольких показателей [14].

Бартини (Robert L. Bertini) и др. использовали время нахождения в пути транспортного средства, данные о скорости движения в Портленде (шт. Орегон, США) для оценки условий дорожного движения [15,16].

Коифман (Benjamin Coifman) и др. использовали средства автоматического определения местоположения автомобилей для измерения времени движения и средней скорости автомобилей на автомагистралях, а также определения существующей дорожно-транспортной обстановки [17].

Дуан (Houli Duan) и др. применили объем и плотность трафика для анализа и наглядного представления трафика [18].

Турочи (Rod Turochy) и др. вычисляют индекс изменчивости на основе многофакторной статистики, используя большую архивную коллекцию данных о трафике. Индекс изменчивости позволяет определять время суток и дни недели, в которые наблюдается высокая степень изменчивости дорожно-транспортной обстановки [19].

Ван (Y. Wang) и др. оценивают дорожно-транспортную обстановку на основе значений переменных трафика, таких как средняя скорость и плотность трафика. Недостатками подхода являются сложность вычислений, трудности в сборе требуемых наборов данных и т.д. [20].

Влахоянни (Eleni I. Vlahogianni) и др. предложили способ объединения временных и пространственных характеристик потока трафика и его оптимизации с помощью генетических алгоритмов, позволяющий лучше прогнозировать потоки трафика по сравнению с другими методами [21].

Инь (Hongbin Yin) и др. использовали нечеткую нейронную модель для прогнозирования потока трафика. Используя нечеткий метод, они разбивают входные данные на несколько кластеров, а затем на основе нейронной сети определяют взаимосвязи между входными и выходными данными. Это увеличивает прогнозирующую способность модели за счет адаптивного регулирования ее коэффициентов в соответствии с текущей дорожно-транспортной обстановкой [22].

Люй (Yisheng Lv) и др. предложили новый метод прогнозирования потока трафика на основе глубокого обучения. В этом методе учитываются корреляции пространственных и временных показателей [23].

Смит (Brian Lee Smith) и др. занимались краткосрочным прогнозированием потока трафика с использованием генетического подхода и показали, что для этого хорошо подходят модели ближайших соседей [24].

Чен (Dawei Chen) и др. предложили комбинацию нейронной сети и пчелиного алгоритма для среды больших данных, которая использовалась в условиях плотного трафика для прогнозирования его потоков и обеспечивала большую точность, чем предыдущие методы [25].

Ма (Xiaolei Ma) и др. предложили использовать для краткосрочного прогнозирования трафика нейронную сеть с кратковременной памятью, которая уменьшает ошибку прогнозирования и позволяет прогнозировать скорость движения [26].

Абдулхай (Baher Abdulhai) и др. разработали метод краткосрочного прогнозирования транспортных потоков, основанный на пространственной информации, и обнаружили, что если исключить пространственную информацию, то ошибка прогнозирования удваивается [27].

Массобрио (Massobrio) и др. Представили открытую транспортную систему, использующую исторические данные автобусного движения для прогнозирования мобильности пассажиров на основе данных о продаже билетов с помощью смарткарт [28].

Аларкон-Акино (Vicente Alarcon-Aquino) и др. предложили многофункциональную нейронную сеть, в которой используются методы теории вейвлетов и которая функционирует лучше некоторых линейных прогнозных систем [29].

Чен (Yuehui Chen) и др. использовали гибкую модель нейронного дерева для мелкомасштабного прогнозирования трафика, которая обеспечивает лучшую точность прогнозирования и меньшую погрешность, чем предыдущие методы [30].

Фаббиани (Fabbiani) и др. строили матрицу исходных и конечных пунктов движения на основе анализа продаж билетов и сведений о локализации автобусов [31].

Янг (Hong-jun Yang) и др. предложили кластерную модель прогнозирования с использованием генетического алгоритма. Модель позволила обеспечить точность краткосрочного прогнозирования потока трафика, более высокую, чем у предыдущих методов. [32].

Лу (Baichuan Lu) и др. для прогнозирования потоков трафика использовали реальные данные трафика, искусственную нейронную сеть и волновые преобразования. Метод позволяет повысить точность предсказаний за счет большего объема вычислений [33].

### 3. Предлагаемый метод

Согласно предыдущим исследованиям, скорость транспортного средства является показателем оценки плотности движения. В нашем исследовании индекс скорости транспортного средства определяется на основе средней скорости движения, максимальной разрешенной скорости и классификационного индекса загруженности дорог.

#### 3.1 Индекс эффективной скорости

Скорость транспортного средства является важным параметром для измерения плотности трафика. Скорость не может превышать 100 км/час, и индекс скорости (со значениями от 0 до 100) представляет собой частное от деления скорости транспортного средства на максимальную разрешенную скорость. В нашем исследовании для оценки дорожно-транспортной обстановки используется индекс эффективной скорости. Для классификации городской дорожно-транспортной обстановки были выбраны четыре пороговых значения: 25, 50, 75, 100. Чем меньше значение индекса эффективной скорости, тем медленнее движется транспорт и тем вероятнее ситуация затора. Основываясь на таких оценках анализ загруженности городской дорожной сети можно вести на основе индекса плотности дорожного сегмента и его измеренных значений. Например, если значение индекса эффективной скорости находится в диапазоне от 0 до 25, среднюю скорость надо считать очень низкой, а загруженность дороги очень высокой. Диапазон от измеренных значений 25-50 показывает среднюю загрузку и невысокую среднюю скорость. В диапазоне 50-75 скорость уже выше, а диапазон 75-100 показывает высокую скорость и хорошие условия для движения транспорта.

Индекс скорости вычисляется по формуле (1). В этой формуле  $V$  – средняя скорость движения,  $V_{max}$  – максимально разрешенная скорость на дорогах и  $R_v$  индекс эффективной скорости:

$$R_v = \frac{V}{V_{max}} \times 100 \quad (1)$$

#### 3.2 Индекс плотности загрузки дорожного сегмента

Для анализа заторов на дорогах используется индекс плотности загрузки дорожного сегмента городских дорожных сетей. Для расчета индекса плотности загрузки сегмента дороги наблюдение велось за трафиком на середине этого сегмента. Индекс плотности дорожного сегмента вычисляется по формулам (2) и (3). Этот индекс находится между 0 и 1, и чем меньше число, тем больше затруднения в трафике. В этих уравнениях  $R_i$  представляет собой индекс плотности загрузки дорожного сегмента,  $R_v$  – индекс эффективной скорости,  $R_{NC}$  – доля времени пребывания дорожного сегмента в незагруженном состоянии,  $t_{NC}$  – время незагруженного состояния (в минутах) и  $t_T$  – период наблюдения (в минутах).

$$R_i = \frac{R_v}{100} \times R_{NC} \quad (2)$$

$$R_{NC} = \frac{t_{NC}}{t_T} \quad (3)$$

#### 3.3. Индекс плотности загрузки дороги

Дорожная сеть состоит из участков дороги, индекс плотности загрузки сегмента дороги вычисляется по формуле (4). Значение индекса плотности дорожной сети находится в пределах от 0 до 1, и чем меньше число, тем больше плотность загрузки дорожной сети. В этой формуле  $R$  – это индекс загрузки дорожной сети, а  $L_i$  – длины отдельных сегментов дорожной сети.

$$R = \frac{\sum_i R_i L_i}{\sum_i L_i} \quad (4)$$

### 4. Опыт проведенных исследований

Авторами были рассмотрены характеристики транспортного движения города Хамедан. В течение почти 10 лет в этом городе проводились активные мероприятия для создания стабильной электронной городской среды. Основная транспортная сеть города Хамедан состоит из двух колец, одного полукольца и шести соединительных линий между кольцами. Авторами была проанализирована информация, полученная на основе данных центра управления движением Хамедана. На рис. 1 показана карта основных дорог города Хамедан, видны кольца и соединительные линии между ними.



Рис. 1. Схема главных дорог города Хамедана и городской центр управления движением

Fig. 1. Scheme of the main roads of the city of Hamedan and the city traffic control center

Результат исследования показывает, что наиболее часто встречающееся значение индекса эффективности скорости, вычисленного по всему массиву зафиксированных в Хамедане скоростей, составляет 65, что превышает 50%. С ростом скорости до значения индекса 60 загруженность дорожной сети растет медленно, а затем темп ее роста возрастает. Средний индекс эффективной скорости на главных дорогах Хамедана, рассчитанный для разного времени суток, приведен в табл. 1.

В таблице 1 строка **WD** представляет рабочие дни недели, а строка **WE** – выходные и праздничные дни. Строка **D** содержит разницу между этими днями. Из таблицы видно, что самые большие различия в скоростях автомобилей зафиксированы в 8, 13 и в 15 часов, и в рабочие дни в эти часы транспорт движется с меньшей скоростью из-за возрастающего трафика. Средняя скорость автомобилей в рабочий день составляет 67,08, средняя скорость в конце недели достигает 69,95.

Табл. 1. Сравнение средней скорости на главных дорогах Хамедана в рабочие (WD) и выходные (WE) дни

Table 1. Comparison of average speed on the main roads of Hamedan on working days (WD) and weekends (WE)

Время суток (час)	0	1	2	3	4	5	6	7	8	9	10	11
Рабочие дни (WD)	72	78	82	90	95	85	81	75	55	60	65	62
Выходные дни (WE)	75	75	80	87	93	82	79	75	72	70	70	65
Разница (D)	3	-3	-2	-3	-2	-3	-2	0	17	10	-5	2
Время суток (час)	12	13	14	15	16	17	18	19	20	21	22	23
Рабочие дни (WD)	58	50	55	57	60	65	63	56	59	60	62	65
Выходные дни (WE)	64	63	65	70	65	65	60	55	60	62	63	64
Разница (D)	6	13	10	13	5	0	-3	-1	1	2	1	-1




Рис. 2. Почасовой индекс эффективности скорости в среднем за один день  
Fig. 2. Hourly average speed efficiency index for one day

Рис. 2 показывает почасовые индексы эффективной скорости в рабочие и выходные дни. Пиковые часы в будние дни обычно возникают утром с 07:00 до 09:00, днем с 12:30 до 14:30, а вечером с 17:00 до 19:00. Самые высокие нагрузки наблюдаются утром, днем и вечером в 8:00, 13:00 и 18:00. Время вечерней пиковой нагрузки на дороги оказывается разным в выходные и будние дни, но утром и днем в будние дни трафик увеличивается больше, чем в выходные. Кроме того, психологически важные часы трафика приходятся на раннее утро, и при этом нет большой разницы между выходными и будними днями.

#### 4.1 Оценка перегрузки сети

На рис. 3 показаны три кривые, демонстрирующие загруженность дорожной сети Хамедана в будние дни. Изменения состояния сети в часы пик утром, днем и вечером, соответственно, показаны с помощью расчета индекса эффективной скорости на дороге каждые 15 минут. Утром, днем и вечером на рисунке 3 (а, б и в) состояние дорожной сети ухудшается, но совсем рано утром ситуация спокойнее.




Рис. 3. Показатели индекса эффективной скорости в часы пик  
Fig. 3. Indicators of the index of effective speed during rush hours

#### 4.2 Прогнозирование загруженности нейронной сетью

Авторы провели исследование изменений скоростей транспортных средств и плотность движения во времени, при этом выявлялась связь средней суточной плотности трафика со снижением скорости движения. Анализ данных о скорости автомобилей проводился с использованием статистического коэффициента корреляции Пирсона, уравнений линейной регрессии, полиномиальной регрессии (полулинейный метод) [34-35] и искусственных нейронных сетей [36-37]. Для точного прогнозирования плотности трафика использовались искусственная нейронная сеть и генетические алгоритмы.

Первоначально данные, используемые в искусственной нейронной сети, были разделены на две отдельные части, причем половина данных предназначалась для обучения сети, а вторая половина данных использовалась для тестирования. В качестве функции стимуляции в методе пост-распространения используется функция Танксона (Tanhon). Эта функция преобразует интервал значений каждого нейрона в интервал, ограниченный значениями -1 и 1. Значения из этого сжатого интервала рассматриваются как коэффициент корреляции. Коэффициент корреляции показывает соотношение между выходом сети и фактическим значением исследуемого параметра. Значение 1, означает точное следование выхода сети за изменением фактического параметра, а -1 означает, что изменения выхода сети и фактического параметра происходят в противофазе. В качестве входного параметра рассматривалась скорость транспортного средства, а выход сети трактовался как плотность трафика. Чтобы уменьшить ошибку прогнозирования, при расчетах параметров сети применялся метод проб и ошибок. Для обучения сети использовалась модель многослойного перцептрона. Для обучения сети использовался один скрытый слой и Дельта-правило с коэффициентом обучения 0.1, контролировавшим степень соответствия весов связей между нейронами.

Количество нейронов скрытого слоя для сетевого обучения было выбрано равным 4 и момент, который является одним из основных параметров обучения и определяет воздействие исходных значений весов связей на новые значения этих весов, равен 0.7.

При анализе регрессионного и полулинейного методов полиномиальный коэффициент корреляции между плотностью трафика и минимальной скоростью транспортного средства составил 0.88% в течение второй половины 2017 года, что является значимым на уровне  $\alpha = 0.01$ , а коэффициент определения рассчитан как 0.77%. Этот анализ показывает, что между средней дневной плотностью трафика и минимальной скоростью движения существует обратная зависимость.

При использовании искусственной нейронной сети результаты, полученные в сети, обученной на регулярно поставляемых примерах, оказываются более хорошими, чем в том случае, когда выбор обучающих примеров осуществляется случайным образом. В реальной жизни метод обратного распространения ошибки (BP) часто работает очень медленно. Для преодоления этой проблемы используется генетический алгоритм выбора лучших первичных весов связей. Ускорения получения результатов можно добиться использованием нейронной сети и ее сочетанием с генетическим алгоритмом.

Сравнение среднесуточной плотности трафика с его прогнозируемым уровнем, полученным на основе случайных данных с использованием генетического алгоритма, показывает, что минимальная среднеквадратичная ошибка (MMSE) в этом режиме равна 0.01, при этом коэффициент корреляции между среднесуточной плотностью трафика и выданным сетью со случайными обучающими данными прогнозом и генетическим алгоритмом составляет 94%, а коэффициент детерминации составляет 0.90.

Сравнение методов линейной и полиномиальной регрессии с использованием искусственной нейронной сети показало, что коэффициент детерминации зависимости средней плотности



трафика с минимальной скоростью транспортного средства в линейной регрессии равен 0.77, в полиномиальной регрессии равен 0.90, а в нейронной сети равен 0.94 (таблица 2).


Табл. 2. Сравнение коэффициентов линейной и полиномиальной регрессии с нейронной сетью

Table 2. Comparison of the coefficients of linear and polynomial regression with a neural network

	Нейронная сеть	Полиномиальная регрессия	Линейная регрессия
Средний коэффициент детерминации	0.94	0.90	0.77

Согласно полученным результатам можно сказать, что нейронная сеть хорошо предсказывает взаимосвязь между средней дневной плотностью трафика и скоростью транспортных средств.

На рис. 4 показано сравнение среднесуточного значения фактической плотности трафика с прогнозируемым числом, полученным на случайных данных совместно с генетическим алгоритмом. Там же показано сравнение среднесуточного фактического количества плотности трафика с прогнозируемым числом, полученным на упорядоченных данных и без генетического алгоритма, а также средние ежедневные данные плотности трафика в упорядоченных данных вместе с генетическим алгоритмом.




a) случайные данные и генетический алгоритм

a) random data and genetic algorithm

b) регулярные данные без применения генетического алгоритма

b) regular data without the use of a genetic algorithm




c) регулярные данные с применением генетического алгоритма

c) regular data using the genetic algorithm

Рис. 4. Сравнение фактической и прогнозируемой плотности трафика

Fig. 4. Comparison of actual and forecasted traffic density

На рис. 5 показаны результаты последующих исследований, выполненных для сравнения данных о фактическом росте загрузки дорог, полученных при наблюдениях в Хамедане, с прогнозами загрузки дорог, рассчитанными на основе использования нейронной сети.




a) случайные данные и генетический алгоритм

a) random data and genetic algorithm


b) регулярные данные без применения генетического алгоритма

b) regular data without the use of a genetic algorithm




c) регулярные данные с применением генетического алгоритма

c) regular data using the genetic algorithm




d) Средняя корреляция, вычисленная на случайных данных с использованием нейронной сети и генетического алгоритма

d) Average correlation calculated on random data using a neural network and a genetic algorithm



e) Средняя корреляция, вычисленная на регулярных данных с использованием нейронной сети

e) Average correlation calculated on regular data using a neural network



f) Средняя корреляция, вычисленная на регулярных данных с использованием нейронной сети и генетического алгоритма

f) Average correlation calculated on regular data using neural network and genetic algorithm

Рис. 5. Среднесуточное сравнение фактической и прогнозируемой плотности трафика

Fig. 5. Average daily comparison of actual and forecasted traffic density

В качестве практического результата проведенного исследования была получена возможность достаточно точного определения географического положения транспортного затора на карте города по выявляемым показателям снижения средней скорости потока.

Выявление узких мест помогает ставить задачу изменения или, по крайней мере, планирования изменений геометрии транспортных путей для балансировки нагрузки на всех альтернативных путях и последующего снижения степени перегруженности сети.

На рис. 6 показаны участки плотных транспортных пробок в городе Хамедан. На этом рисунке видно, что неравномерности в росте города Хамедан приводят к затруднениям движения в некоторых частях города в часы пик. С другой стороны, в другой части города загруженности трафика не наблюдается, и движение продолжается без особых затруднений. Приведенная иллюстрация показывает, что в часы пиковой загруженности трафика те точки на карте городских районов, где имеются затруднения в движении транспорта, должны быть исправлены.




Рис. 6. Отображение мест плотного движения в городе Хамедан в часы пик  
Fig. 6. Display of heavy traffic in Hamedan during rush hours

Авторы тестировали возможность использования специализированного программного инструмента, разработанного компанией IBM (IBM Traffic Prediction Tool) для исследования условий движения транспорта в Сингапуре. Этот инструментарий позволяет также делать прогнозы относительно времени возвращения трафика к нормальному уровню, что достигается использованием видеонаблюдения, системы позиционирования GPS, системы управления такси и датчиков, установленных на улицах. Такой подход оказывается значительно более дорогостоящим, чем метод, предложенный в настоящей статье, который не требует дорогого оборудования и существенного накопления больших массивов информации [38].

Авторами была рассмотрена модель, предложенная компанией Яндекс (Yandex), которая выдает рекомендации по управлению трафиком на основе собираемой информации. При выработке этих рекомендаций учитываются географические координаты, порядок и скорость движения транспорта. Ошибки в отслеживании положения транспортных средств на дороге исправляются с помощью сигналов от глобальных систем позиционирования (например, GPS). Система позволяет находить правильный маршрут, базируясь на собственном методе маршрутизации, и хорошо подходит для крупных пространств. Проект Яндекса зависит от глобального позиционирования, в то время, как метод, представленный в этой статье, такой зависимости не имеет [39].

Для повышения точности проведения исследований в Хамедане был выбран район с напряженным потоком движения. Было проведено моделирование реального перекрестка – на южной стороне площади Джахад в городе Хамедан. Этот перекресток окружен жилыми и коммерческими кварталами, ключевыми зданиями, он характеризуется большим количеством пешеходов и транспортных средств. В данном случае рассматривались только потоки транспорта в определенные рабочие дни, при этом изучались различия в характере движения. Использовались данные о потоках движения с 6 до 8 марта и с 23 до 25 мая (фиксация данных в каждом интервале осуществлялась каждые 15 минут). Были получены и изучены 288 наборов данных по каждому временному интервалу, то есть всего 576 наборов. Например, для прогнозирования транспортных потоков использовались данные, полученные с нуля часов 23-го мая до 24 часов 25-го мая.

Сравнение методов оценки, выполнявшееся авторами настоящей работы, базируется на концепции анализа временных рядов ARIMA (авторегрессивное интегрированное скользящее среднее), используемой в качестве модели нестационарного временного ряда, формировавшегося с 1979 по 2018 год с некоторыми изменениями, вносившимися для более полного использования преимуществ конкретных приложений. Тань (Tang) в 2018 году, используя ту же концепцию, рассматривал транспортный поток как нестационарную случайную последовательность [40]. Другим возможным методом анализа является разрабатывавшийся с 2002 по 2015 год метод WNN (вейвлет-нейронная сеть), то есть нелинейная волновая нейронная сеть. Этот метод основан на использовании вейвлета в качестве функции активации для скрытых узлов и весов входных нейронов [41].

Циньчжун Хоу (Qinzhong Hou) и его коллеги также предложили комбинацию вышеуказанных методов, названную ими гибридной моделью ARIMA & WNN, в которой веса назначаются на основе нечетких вычислений [42]. Для этой модели, представленной ее авторами в 2019 году, были по формулам (5) в процентах рассчитаны фактическая относительная погрешность выхода RPE (relative pointing error), средняя процентная абсолютная ошибка MAPE (mean percentage absolute error) и корень среднеквадратичной погрешности RMSE (root mean square error). В приведенных формулах  $u_t$  – наблюдаемый трафик,  $Q_t$  – результат прогнозирования,  $l$  – количество сделанных наблюдений [42].

$$\begin{aligned} MAPE &= \frac{1}{l} \sum_{t=1}^l \left| \frac{u_t - Q_t}{u_t} \right| \times 100, \\ RPE &= \frac{|u_t - Q_t|}{u_t} \times 100, \\ RMSE &= \sqrt{\left( \frac{1}{l} \times \sum_{t=1}^l \left( \frac{u_t - Q_t}{u_t} \right)^2 \right)} \times 100. \end{aligned} \quad (5)$$

Табл. 3, содержащая данные о сравнении различных моделей оценки результатов моделирования, показывает, что предлагаемый авторами метод намного лучше, чем предыдущие методы. В этом методе с учетом различий в трафике в разные месяцы были рассмотрены два сценария трафика в марте месяце и трафик с фиксированной скоростью в мае. Предложенный метод (сам по себе и в сочетании с вейвлет-нейронной сетью) был также сравнен с ранее использовавшимися методами.

Табл. 3. Сравнение предлагаемого метода оценки результата с ранее использовавшимися методами по данным, полученным в марте и мае соответственно

Table 3. Comparison of the proposed method for evaluating the result with previously used methods according to the data obtained in March and May, respectively

index	ARIMA	WNN	HYBRID ARIMA&WNN	PROPOSED <sup>1</sup>	PROPOSED 2 & WNN
RPE	15.64	13.49	4.07	3.97	3.12
MAPE	9.91	7.65	5.98	5.42	4.83
RMSE	8.49	7.31	6.12	5.72	5.01
RUNNINGTIME	14.33	3.59	17.36	12.41	10.24

index	ARIMA	WNN	HYBRID ARIMA&WNN	PROPOSED <sup>1</sup>	PROPOSED 2 & WNN
RPE	13.12	12.03	3.84	3.61	3.57
MAPE	8.84	6.16	5.12	5.01	5.01
RMSE	7.24	5.82	5.72	5.20	5.11
RUNNINGTIME	12.48	1.74	15.72	13.01	13.96

## 5. Заключение

В проведенном исследовании первоначально в качестве индекса оценки был выбран почасовой показатель скорости. Основываясь на выполненном исследовании, было выявлено, в какое время в городе Хамедан возрастает количество пробок, а движение транспортных средств замедляется. Было определено, что в среднем в течение дня три раза наблюдается замедление движения транспортных средств и увеличение плотности трафика. В часы пик утром, днем и вечером на дорогах возникают задержки и заторы, длящиеся около двух часов.

На основе анализа географии сети основных дорог Хамедана была повышена точность получаемых данных и улучшено понимание ситуации с сетевым трафиком в Хамедане, что создает основу для управления трафиком в будущем.

Одновременно на основе использования нейронной сети была выявлена связь между снижением скорости городских транспортных средств и увеличением плотности движения. Полученные результаты показали, что обучение сети на упорядоченных данных дает лучшие результаты при прогнозировании среднесуточной загруженности, нежели такое обучение на случайных данных. При этом в случае комбинирования генетического алгоритма и нейронной сети скорость анализа и точность прогнозов возрастают, а ошибки снижаются.

Выявление мест на городских дорогах, где возникают заторы при движении транспорта, также помогает идентифицировать пробки города и регистрировать связанные с ними события в электронных системах города, проводить изменения топологии дорог и строить новые дороги там, где это необходимо для улучшения условий движения. Авторам удалось выявить условия, возникающие на дорогах города Хамедан в часы пик. В дальнейшем можно будет устранить проблемы движения в городе, можно будет так вести планирование трафика, чтобы минимизировать длительность заторов и улучшить эту ситуацию в городе.

## Список литературы / References

- [1] Chourabi H., Nam T., Walker S., Gil-Garcia J.R., Mellouli S., Nahon K., Pardo T.A., Scholl J. Understanding smart cities: An integrative framework. In Proc. of the 45th Hawaii International Conference on System Science, 2012, pp.2289-2297.
- [2] Rashid B., Rehmani M.H. Applications of wireless sensor networks for urban areas: A survey. Journal of Network and Computer Applications, vol. 60, 2016, pp. 192–219.

- [3] Sahoo J., Cherkaoui S., Hafid A. A novel vehicular sensing framework for smart cities. In Proc. of the 39th Annual IEEE Conference on Local Computer Networks, 2014, pp. 490–493.
- [4] Al-Turjman F., Hassanein H., Ibnkahla M. Efficient deployment of wireless sensor networks targeting environment monitoring applications. Computer Communications, vol. 36, issue 2, 2013, pp. 135–148.
- [5] Al-Turjman F. Cognitive-node architecture and a deployment strategy for the future sensor networks. Mobile Networks and Applications, vol. 24, issue 5, pp. 1663-1681.
- [6] Geisler S., Quix C., Schiffer S., Jarke M. An evaluation framework for traffic information systems based on data streams. Transportation Research, Part C: Emerging Technologies, vol. 23, 2012, pp. 29-55
- [7] Anthopoulos L., Fitsilis P. From Online to Ubiquitous Cities: The Technical Transformation of Virtual Communities. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol. 26, 2009, pp. 360-372.
- [8] Shwayri S.T. A model Korean ubiquitous eco-city? The politics of making Songdo. Journal of Urban Technology, vol. 20, issue 1, 2013, pp. 39-55.
- [9] Sanchez L. et al. SmartSantander: IoT experimentation over a smart city testbed. Computer Networks, vol. 61, 2014, pp. 217-238.
- [10] Bakici T., Almirall E., Wareham J. A smart city initiative: the case of Barcelona. Journal of the Knowledge, vol. 4, issue 2, 2013, pp. 135-148.
- [11] Jia S., Peng H., Liu S. Urban traffic state estimation considering resident travel characteristics and road network capacity. Journal of Transportation Systems Engineering and Information Technology, vol. 11, issue 5, pp. 81-85.
- [12] Zhu F. Research on index system of urban traffic congestion measures. Master Degree thesis. Nanjing, Jiangsu, China, Southeast University. 2006, pp. 4-15 (in Chinese).
- [13] Quiroga C.A. Performance measures and data requirements for congestion management systems. Transportation Research, Part C: Emerging Technologies, vol. 8, issue 1, 2000, pp. 287-306.
- [14] Robert R., Theodore F. Contrasting the Use of Time-Based and Distance-Based Measures to Quantify Traffic Congestion Levels: An Analysis of New Jersey Counties. In Proc. of the 81th Annual Meetings of the Transportation Research Board, 2002.
- [15] Bertini R.L., Leal M., Lovell D.J. Generating Performance Measures from Portland's Archived Advanced Traffic Management System Data. In Proc. of the 81th Annual Meetings of the Transportation Research Board, 2002.
- [16] Bertini R.L., Tantiyanugulchai S. Transit buses as traffic probes: Use of geolocation data for empirical evaluation. Journal of the Transportation Research Board, vol. 1870, issue 1, 2004, pp. 35-45.
- [17] Coifman B., Kim S.B. Measuring freeway traffic conditions with transit vehicles. Journal of the Transportation Research Board, vol. 2121, issue 1, 2009, pp. 90-101.
- [18] Houli D. et al. Network-wide traffic state observation and analysis method using pseudo-color map. Journal of Transportation Systems Engineering and Information Technology, vol. 9, issue 4, 2009, pp. 46-52.
- [19] Turochy R.E., Smith B.L. Measuring variability in traffic conditions by using archived traffic data. Journal of the Transportation Research Board, vol. 1804, issue 1, 2002, pp. 168-172.
- [20] Wang Y., Papageorgiou M., Messmer A. Real-time freeway traffic state estimation based on extended Kalman filter: Adaptive capabilities and real data testing. Transportation Research, Part A: Policy and Practicem, vol. 42, issue 10, 2008, pp. 1340-1358.
- [21] Vlahogianni E.I., Karlaftis M.G., Golias J.C. Optimized and meta-optimized neural networks for short-term traffic flow prediction: A genetic approach. Transportation Research, Part C: Emerging Technologies, vol. 13, issue 3, 2005, pp. 211-234.
- [22] Yin H., Wong S., Xu J., Wong C.K. Urban traffic flow prediction using a fuzzy-neural approach. Transportation Research, Part C: Emerging Technologies, vol. 10, issue 2, 2002, pp. 85-98.
- [23] Lv Y., Duan Y., Kang W., Li Z., Wang F.Y. Traffic flow prediction with big data: a deep learning approach. IEEE Transactions on Intelligent Transportation Systems, vol. 16, issue 2, 2015, pp. 865-873.
- [24] Smith B.L., Demetsky M.J. Short-term traffic flow prediction models-a comparison of neural network and nonparametric regression approaches. In Proc. of the IEEE International Conference on Systems, Man and Cybernetics, vol. 2, 1994, pp. 1706-1709.
- [25] Chen D. Research on traffic flow prediction in the big data environment based on the improved RBF neural network. IEEE Transactions on Industrial Informatics, vol. 13, issue 4, 2017, pp. 2000-2008.

- [26] Ma X., Tao Z., Wang Y., Yu H., Wang Y. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research, Part C: Emerging Technologies*, vol. 54, 2015, pp. 187-197.
- [27] Abdulhai B., Porwa H., Recker W. Short-term traffic flow prediction using neuro-genetic algorithms. *Journal-Intelligent Transportation Systems Journal*, vol. 7, issue 1, 2002, pp. 3-41.
- [28] Massobrio R., Nesmachnow S., Tchernykh A. et al. Towards a Cloud Computing Paradigm for Big Data Analysis in Smart Programming and Computer Software, vol. 44, issue 3, 2018, pp. 181-189.
- [29] Alarcon-Aquino V., Barria J.A. Multiresolution FIR neural-network-based learning algorithm applied to network traffic prediction. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 36, issue 2, 2006, pp. 208-220.
- [30] Chen Y., Yang B., Meng Q. Small-time scale network traffic prediction based on flexible neural tree. *Applied Soft Computing*, vol. 12, issue 1, 2012, pp. 274-279.
- [31] Fabbiani E., Nesmachnow S., Toutouh J. et al. Analysis of Mobility Patterns for Public Transportation and Bus Stops Relocation. *Programming and Computer Software*, vol. 44, issue 6, 2018, pp. 508-525.
- [32] Yang H. J., Hu X. Wavelet neural network with improved genetic algorithm for traffic flow time series prediction. *Optik*, vol. 127, issue 19, 2016, pp. 8103-8110.
- [33] Lu B., Huang M. Traffic flow prediction based on wavelet analysis, genetic algorithm and artificial neural network. In *Proc. of the 2009 International Conference on Information Engineering and Computer Science*, 2009, pp. 1-4.
- [34] Yi J., Prybutok V.R. A neural network model forecasting for prediction of daily maximum ozone concentration in an industrialized urban area. *Environmental Pollution*, vol. 92, issue 3, 1996, pp. 349-357.
- [35] Grandner M.W., Dorling S.R. Neural network modeling and prediction of hourly NO<sub>x</sub> and NO<sub>2</sub> concentrations in urban air in London. *Atmospheric Environment*, vol. 33, issue 5, 1999, pp. 709-719.
- [36] Mobley B.A. et al. Predictions of coronary artery stenosis by artificial neural network. *Artificial Intelligence in Medicine*, vol. 18, issue 3, 2000, pp. 187-203.
- [37] Boone J.M. X-ray spectral reconstruction from attenuation data using neural networks. *Medical Physics*, vol. 17, issue 4, 1990, pp. 647-654.
- [38] IBM Traffic Prediction Tool – IBM Research. Available at: [https://researcher.watson.ibm.com/researcher/view\\_group\\_subpage.php?id=1248](https://researcher.watson.ibm.com/researcher/view_group_subpage.php?id=1248)
- [39] Как работают Яндекс.Пробки / How Yandex.Traffic Works, available at: <https://yandex.ru/company/technologies/yaprobki/> (in Russian).
- [40] Tang T.Q., Yi Z.Y., Zhang J., Wang T., Leng J.Q. A speed guidance strategy for multiple signalized intersections based on car-following model. *Physica A: Statistical Mechanics and its Applications*, vol. 496, 2018, pp. 399-409.
- [41] Moretti F., Pizzuti S., Panzieri S., Annunziato M. Urban traffic flow predicting through statistical and neural network bagging ensemble hybrid modelling. *NeuroComputing*, vol. 167, 2015, pp. 3-7.
- [42] Hou Q., Leng J., Maa G., Liu W., Cheng Y. An adaptive hybrid model for short-term urban traffic flow prediction. *Physica A: Statistical Mechanics and its Applications*, vol. 527, 2019, article 121065.

## Информация об авторах / Information about authors

Мехди ШИРМОХАММАДИ получил степень магистра в области информационных технологий в Казвиносском филиале Исламского университета Азад, он является аспирантом в области компьютерных программных систем в Аракском филиале Исламского университета Азада. В настоящее время он преподает на факультете компьютерной инженерии Хамеданского филиала Исламского университета Азад. Его основные научные интересы: сенсорные сети и системы принятия решений.

Mehdi SHIRMOHAMMADI received his MS degree in Information Technology from Islamic Azad University, Qazvin Branch, Qazvin, Iran and he is PhD student in Computer Engineering-Software systems in Islamic Azad University, Arak Branch, Arak, Iran. He is currently lecturer at Department of Computer Engineering, Islamic Azad University, Hamedan Branch, Hamedan, Iran. His main research interest is Sensor networks and decision systems.

Мансур ЭСМАИЛПУР получил степень кандидата компьютерных наук в Национальном университете Малайзии, Малайзия, в 2011 году. Он является доцентом кафедры вычислительной техники и разработки программного обеспечения отделения Хамеданского

филиала Исламского университета Азад. Он активно консультирует промышленность и участвует в нескольких проектах по исследованию и передаче технологий, осуществляемых в сотрудничестве с промышленными партнерами. Его исследовательские интересы включают архитектуру программного обеспечения, электронное обучение, интеллектуальный анализ данных и системы обучения. Он является членом IEEE, IEEE Computer Society и ACM.

Mansour ESMAEILPOUR received the PhD degree in Computer Science from the National University of Malaysia, Malaysia, in 2011. He is an Assistant professor of Computer Engineering, Software Engineering Department of the Islamic Azad University Hamedan Branch, Hamedan, Iran. He is actively consulting in industry and has been involved in several research and technology transfer projects conducted in cooperation with industrial partners. His research interests include software architecture, e-learning, data mining and learning systems. He is a member of the IEEE, the IEEE Computer Society, and ACM.