

Научная статья

Статья в открытом доступе

УДК 004.89

doi: 10.30987/2658-6436-2024-2-45-53

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ПАРАМЕТРОВ ТРАНСПОРТНЫХ ПОТОКОВ В ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ СВЕТОФОРНОГО РЕГУЛИРОВАНИЯ

Михаил Александрович Стрижко

Донецкий национальный технический университет, г. Донецк, Россия

strizhko.mihail@yandex.com, <https://orcid.org/0009-0007-2702-5194>

Аннотация. Предложен способ нейросетевого прогнозирования загруженности участков дороги вне зон контроля детекторов транспорта в системах «гибкого» управления транспортными потоками на перекрестках со светофорным регулированием. Описан принцип работы исходной системы управления на основе нечеткой логики. Для разработки универсального нейросетевого решения, которое может быть применено для прогнозирования трафика на большинстве участков дорог с распространенными характеристиками без необходимости обучения для каждого случая в отдельности, предложено выделить 9 основных типов участков и, соответственно, 9 нейронных сетей. Каждая типовая нейронная сеть отличается объемом входных данных и параметрами. Все нейронные сети обучаются на выборках, полученных при анализе транспортного потока на участках дорог каждого типа. Определены типовые характеристики участков дорог, архитектура и параметры нейронных сетей. Произведено обучение и тестирование нейронных сетей на модельных данных. Методами имитационного компьютерного моделирования произведена оценка качества управления исходной интеллектуальной системой светофорного регулирования, имеющей полную информацию о транспортном потоке (однако труднореализуемой на практике), а также системы управления, использующей совокупность данных, полученных при помощи детекторов транспорта и дополненных нейросетевым прогнозом. По результатам эксперимента система с нейросетевым прогнозом загруженности участков дороги по сравнению с идеализированной системой по качеству управления уступает не более, чем на 1,92 %, что даёт основания считать данный способ применимым в интеллектуальных системах управления транспортными потоками на перекрестках со светофорным регулированием.

Ключевые слова: транспортный поток, система управления, прогнозирование, нейронная сеть, временной ряд, участок дороги

Для цитирования: Стрижко М.А. Нейросетевое прогнозирование параметров транспортных потоков в интеллектуальных системах светофорного регулирования // Автоматизация и моделирование в проектировании и управлении. 2024. №2 (24). С. 45-53. doi: 10.30987/2658-6436-2024-2-45-53.

Original article

Open Access Article

NEURAL NETWORK FORECASTING OF TRANSPORT FLOW PARAMETERS IN INTELLIGENT TRAFFIC LIGHT CONTROL SYSTEMS

Mikhail A. Strizhko

Donetsk National Technical University, Donetsk, Russia

strizhko.mihail@yandex.com, <https://orcid.org/0009-0007-2702-5194>

Abstract. A method is proposed for neural network prediction of congestion on road sections outside the control zones of transport detectors in the systems of “flexible” transport flow control at intersections with the traffic light regulation. The paper describes the operating principle of the original control system based on fuzzy logic. To develop a universal neural network solution that can be used to predict traffic on most road sections with common characteristics without the need for training for each case separately, it is proposed to identify 9 main types of sections and, accordingly, 9 neural networks. Each typical neural network differs in the amount of the input data and parameters. All neural networks are trained on samples obtained from analyzing traffic flow on road sections of each type. Typical characteristics of road sections, architecture, and parameters of neural networks are determined. Neural networks are trained and tested on the model data. Using computer simulation methods, the author assesses the control quality of the original intelligent traffic light control system, which has complete information about the transport flow (however, it is difficult to implement in practice), as well as a control system that uses a set of data obtained using transport detectors and supplemented with a neural network forecast. According to the experiment results, a system with a neural network fore-

cast of congestion on road sections is inferior in quality of control by no more than 1.92% compared to an idealized system, which gives grounds to consider this method applicable in intelligent transport flow control systems at intersections with traffic light regulation.

Keywords: transport flow, control system, forecasting, neural network, time series, road section

For citation: Strizhko M.A. Neural Network Forecasting of Transport Flow Parameters in Intelligent Traffic Light Control Systems. Automation and modeling in design and management, 2024, no. 2 (24). pp. 45-53. doi: 10.30987/2658-6436-2024-1-45-53.

Введение

В условиях быстро возрастающей загруженности дорожной сети в мегаполисах все более острой становится проблема возникновения заторов и увеличения транспортных задержек. Одно из решений данной проблемы заключается в разработке систем «гибкого» управления транспортными потоками, которые учитывают интенсивность движения на подъездах к перекрестку в реальном времени и на основании полученных данных определяют длительности фаз регулирования. Управление движением на перекрестках, осуществляемое сотрудником полиции, является примером наиболее гибкого регулирования, а современные технические средства позволяют увеличить объем информации о трафике и повысить за счет этого качество управления. Однако для получения необходимых статистических данных, как правило, требуется наличие достаточно большого количества детекторов транспорта, что приводит к повышению затрат на реализацию и дальнейшее обслуживание систем управления, возникновению трудностей с установкой и настройкой оборудования. В связи с этим актуальной является проблема прогнозирования параметров транспортного потока в тех зонах дорожной сети городов, где получение этой информации при помощи соответствующего оборудования затруднено.

Описание системы управления

В статье выполняется научно-исследовательская работа по синтезу интеллектуальных систем управления транспортными потоками на перекрестках со светофорным регулированием [1]. Система управления, основанная на нечеткой логике, предполагает разделение дорожной сети на подъездах к перекрестку на участки с присвоением номера каждому из них по удалению от перекрестка и классификацию загруженности каждого участка категориями МАЛО МАШИН (S), СРЕДНЕ МАШИН (M), МНОГО МАШИН (B). При помощи нечеткой логики по номеру участка определяется принадлежность каждой категории загруженности к нечетким множествам БЛИЗКО, СРЕДНЕ, ДАЛЕКО. Выходной переменной системы является уровень целесообразности переключения фазы регулирования в текущий момент времени в диапазоне от 0 до 1. Если значение данной величины превышает 0,5, происходит смена фазы регулирования для пропуска транспорта в конфликтующем направлении. В противном случае продолжается текущая фаза регулирования. Классификация входных данных разработанной системы управления представлена на рис. 1.




Рис. 1. Классификация входных данных системы управления
 Fig. 1. Classification of control system input data

Данный подход позволяет учитывать разрывы и микроколебания транспортного потока, возникающие вследствие взаимосвязи перекрестка с соседними светофорными объектами, с целью повышения эффективности пропуска транспортных средств.

Необходимая дальность обнаружения транспортных средств на подъездах к перекрестку может быть определена исходя из следующих соображений: системе необходимо обнаружить все транспортные средства, движение которых будет прервано при включении запрещающей фазы регулирования на минимальную продолжительность. С учетом ограничения скорости в зоне обнаружения трафика перед перекрестком данная величина может быть вычислена по формуле (1). Минимальная продолжительность запрещающей фазы регулирования на практике рассчитывается с учетом ширины проезжей части и скорости движения пешеходов по формуле (2) [2].

$$l_{\text{обн}} = t_{\text{min}} \cdot V, \quad (1)$$

где $l_{\text{обн}}$ – дальность обнаружения транспортных средств; t_{min} – минимальная длительность запрещающей фазы регулирования; V – ограничение максимальной скорости на данном участке.

$$t_{\text{min}} = 5 + B_{\text{пш}}/V_{\text{пш}}, \quad (2)$$

где t_{min} – длительность фазы регулирования с учетом движения пешеходов; $B_{\text{пш}}$ – ширина проезжей части в месте пешеходного перехода; $V_{\text{пш}}$ – средняя скорость пешехода (обычно принимается равной 1,3 м/с);

Так, при минимальной продолжительности запрещающей фазы регулирования равной 15 с и ограничении скорости в 60 км/ч (16,67 м/с) необходимая дальность обнаружения транспортных средств на подъезде к перекрестку составит 250 м.

Большинство современных детекторов транспорта в условиях города имеют радиус действия 40...100 м. Расстояние между светофорными объектами в городе может достигать 500 м и более. Таким образом, детекторы транспорта, установленные навстречу друг другу на соседних перекрестках, часто не способны получать данные о загруженности всей необходимой зоны обнаружения. Пример расположения участков с обнаружением трафика и «слепых» участков приведен на рис. 2.




Рис. 2. Отслеживаемые и «слепые» участки проезжей части между перекрестками
 Fig. 2. Monitored and "blind" sections of the road between intersections

Решением данной проблемы может быть установка дополнительных детекторов транспорта, что приводит к повышению затрат на реализацию системы. Альтернативным вариантом является применение методов прогнозирования загруженности «слепых» участков на основании имеющейся информации о загруженности соседних участков.

Способ нейросетевого прогнозирования загруженности участков дорожной сети

Прогнозирование временных рядов может быть реализовано различными способами, среди которых наиболее распространенными являются методы экстраполяции и машинного

обучения. Как правило, они основаны на использовании предыдущих значений временного ряда для прогнозирования текущих или будущих значений. Среди методов экстраполяции выделяют метод скользящей средней [3], экспоненциальное сглаживание [4] и метод Хольта-Винтерса [5]. Методы машинного обучения основаны на применении нейросетей [6 – 8]. Обычно они являются более точными, чем методы экстраполяции. Также, наряду с предыдущими значениями прогнозируемого временного ряда, они позволяют учитывать значения других временных рядов, оказывающих влияние на рассматриваемый. Однако применение нейронных сетей предполагает их обучение на каждом участке дороги, что при массовом применении данного метода требует большого объема вычислительных ресурсов системы, и возможности получения обучающих данных на каждом отдельном участке, что при отсутствии стационарных детекторов транспорта весьма затруднительно. Для решения проблемы предлагается выделить типовые участки дорожной сети с определенными параметрами трафика и использовать ограниченное количество нейросетей, с различными параметрами и обучающими данными для прогноза транспортного потока на участке каждого типа.

Основными характеристиками участка дорожной сети приняты:

- длина участка;
- ограничение максимальной скорости движения на участке;
- количество полос движения в одном направлении.

Расстояние между перекрестками может быть любым в достаточно широких пределах, в связи с этим длина участка также варьируется и типизировать её затруднительно. Принимая равными длины участков с прогнозируемым трафиком и участков, обслуживаемых детекторами транспорта, можно установить, длина одного участка не превышает дальность действия детектора транспорта и равна отношению расстояния между перекрестками к количеству участков (3).

$$l_{\text{уч}} = S/n \leq R_{\text{дт}}, \quad (3)$$

где $l_{\text{уч}}$ – длина одного участка; S – расстояние между перекрестками; n – количество участков между перекрестками; $R_{\text{дт}}$ – дальность действия детектора транспорта.

Дальность действия одного из распространенных радиолокационных детекторов транспорта составляет 42,7 м. Принимая данное значение в качестве ограничения максимальной длины участка, рассчитаем количество участков для диапазона расстояний между перекрестками от 200 до 500 м с округлением до большего целого. График зависимости количества участков, ограниченных дальностью действия детектора транспорта, от расстояния между перекрестками представлен на рис. 3.




Рис. 3. Зависимость количества участков проезжей части от расстояния между перекрестками
Fig. 3. Dependence of the number of road sections on the distance between intersections

Для того же диапазона расстояний между перекрестками рассчитана длина участка с установленным ограничением в 42,7 м (рис. 4).




Рис. 4. Зависимость длины участка проезжей части от расстояния между перекрестками
Fig. 4. Dependence of the road section length on the distance between intersections

Из графика видно, что длина участка варьируется в диапазоне от 36 до 42,7 м. Таким образом, максимальная разница между возможными значениями длины участка составляет 6,7 м в диапазоне изменения расстояния между перекрестками от 200 до 250 м. Принимая среднюю длину легкового транспортного средства равной 4,2 м [9], а безопасную дистанцию между автомобилями равной 3 м [10] (в сумме 7,2 м), можно сделать вывод, что вариация длины участка в 6,7 м может внести погрешность в прогнозируемое количество транспортных средств лишь на 1 единицу. Таким образом, длину участка для расстояний между перекрестками в диапазоне от 200 до 500 м можно установить усредненной, равной 39,6 м. При этом допускается пересечение участков или образование зазора между ними для равномерного покрытия всего расстояния между перекрестками.

В условиях российского города наиболее распространены 3 варианта ограничения скорости: 40, 50 и 60 км/ч. По количеству полос движения в одном направлении выделяются участки с 1, 2 и 3 полосами.

Таким образом, получены 9 различных типов участков, прогнозирование транспортного потока на которых требует применения нейросетей с различными параметрами, обученные на различных наборах данных.

Для прогнозирования трафика предлагается использовать нелинейную регрессионную нейросеть прямого распространения. Текущее значение переменной $y(t)$ необходимо спрогнозировать на основании прошлых значений переменных $x_{11}(t) \dots x_{1i}(t), x_{21}(t) \dots x_{2i}(t)$. Выходная переменная $y(t)$ – количество автомобилей на участке на одной полосе движения, подлежащее восстановлению при помощи прогноза. Входная переменная $x_{1i}(t)$ – количество автомобилей на вышестоящем соседнем участке с известными параметрами транспортного потока по i -ой полосе движения. Входная переменная $x_{2i}(t)$ – количество автомобилей на нижестоящем соседнем участке с известными параметрами транспортного потока по i -ой полосе движения. Данная модель может быть описана формулой (4).

$$y(t) = f(x_{11}(t - 1), \dots, x_{11}(t - d), \dots, x_{1i}(t - 1) \dots x_{1i}(t - d), x_{21}(t - 1), \dots, x_{21}(t - d), \dots, x_{2i}(t - 1) \dots x_{2i}(t - d)) \quad (4)$$

Нейросеть состоит из входного, скрытого и выходного слоев. Входной вектор задержек определяет какое количество прошлых значений входных переменных должно учитываться при прогнозе выходной переменной. Количество нейронов на скрытом слое определяется для нейросети каждого типа, исходя из количества полос в одном направлении движения. Архитектура нейронной сети представлена на рис. 5.




Рис. 5. Архитектура нейронной сети для прогнозирования трафика
 Fig. 5. Traffic forecasting neural network architecture

Параметры нейросети для использования на участках различных типов приведены в табл. 1.

Таблица 1

Параметры нейросети, требуемые для использования на участках различных типов

Table 1

Neural network parameters required for use on different types of sections

Ограничение скорости на участке	Количество полос на участке	Количество входов нейросети	Количество нейронов на скрытом слое
60 км/ч	1	14	14
	2	28	28
	3	42	42
50 км/ч	1	14	14
	2	28	28
	3	42	42
40 км/ч	1	14	14
	2	28	28
	3	42	42

При движении автомобилей со скоростью 60 км/ч участок длиной 39,6 м будет преодолен приблизительно за 2 с. Так как средняя скорость транспортного потока, как правило, меньше ограничения максимальной скорости, вектор задержек увеличен до 7 с. Принимая шаг дискретизации задержек равным 1 с, для двух отслеживаемых параметров на входе количество входных временных рядов составляет 14. Количество нейронов на скрытом слое также принимается равным 14. Размер вектора задержек в 7 с, выбранный для типа участков с ограничением скорости движения в 60 км/ч подходит для использования и на участках с меньшим ограничением скорости за счет запаса времени, но требуется использование различных обучающих выборок для каждого типа участка. Для участков с несколькими полосами движения количество отслеживаемых параметров увеличивается. В таком случае на вход нейросети поступают временные ряды по каждой полосе движения с вышестоящего и нижестоящего соседних участков. Количество входов и нейронов на скрытом слое увеличивается в 2 и в 3 раза и составляет 28 и 42.

Обучение нейронной сети и оценка качества прогнозирования

Для обеспечения наилучшего качества прогнозирования обучение нейросети должно осуществляться с использованием набора данных, полученных в реальных условиях при помощи детекторов транспорта. Однако ввиду того, что сбор статистической информации о транспортном потоке с использованием специального оборудования затруднителен, данные для обучения нейросети получены при помощи модели.

Обучающие выборки состоят из данных о количестве автомобилей на участках каждого типа за период в 10 000 с. Обучение нейросети производится методом Левенберга-Марквардта. Тестовая выборка содержит модельные данные о количестве автомобилей на других участках того же типа за период в 2000 с.

Качество прогнозирования оценивается на основании двух показателей: среднеквадратического отклонения между выходными данными нейросети и целевыми значениями S (4), а также коэффициента корреляции между данными величинами R (5).

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2}; \quad (4)$$

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (5)$$

где x – целевая выборка; y – прогнозная выборка; \bar{x} – среднее арифметическое целевой выборки; \bar{y} – среднее арифметическое прогнозной выборки; n – число элементов в выборке.

Показатели качества прогнозирования для участков каждого типа приведены в табл. 2. Результаты обучения нейросети для одного из типов участков проиллюстрированы на рис. 6.

Таблица 2

Показатели качества прогнозирования трафика на типовых участках проезжей части

Table 2

Traffic forecasting quality indicators on typical road sections

Ограничение скорости	Количество полос	S	R
60 км/ч	1	0,060	0,93
	2	0,083	0,91
	3	0,091	0,88
50 км/ч	1	0,059	0,93
	2	0,079	0,94
	3	0,088	0,90
40 км/ч	1	0,061	0,92
	2	0,080	0,94
	3	0,090	0,89




Рис. 6. График целевых и прогнозных данных нейросети

Fig. 6. Graph of target and forecast neural network data

Для оценки влияния применения нейросетевого прогнозирования трафика в разработанной системе на качество управления был проведен модельный эксперимент для системы, осуществляющей управление на основе полной информации о транспортном потоке (труднореализуемой на практике) и для разработанной системы управления, использующей прогнозные данные нейросети. Сравнение показателей качества исследуемых вариантов системы управления транспортными потоками приведено на рис. 7.




Рис. 7. Показатели качества исследуемых систем управления:

a – среднее время ожидания; *b* – средняя длина очереди

Fig. 7. Quality indicators of the control systems:

a – average waiting time; *b* – average queue length

Качество управления оценивалось по таким показателям, как среднее время ожидания и средняя длина очереди. Использование нейросетевого прогноза по качеству управления отличается в среднем на 1,92 % по обоим показателям по сравнению с системой с полной информацией о трафике.

Заключение

В работе предложен способ прогнозирования загруженности участка дороги на подъезде к перекрестку на основе нейронной сети для использования в системах «гибкого» управления транспортными потоками на перекрестках со светофорным регулированием. Описан принцип работы исходной системы управления. Для получения универсального решения предложено выделить 9 основных типов участков дорог и 9 нейросетей с различным объемом входных данных и различными параметрами, предварительно обученных на выборках, соответствующих трафику на участке каждого типа. Описан выбор типовых характеристик участков и параметров нейросети. Произведено обучение нейросети на данных, полученных при помощи модели, приведены результаты её проверки на тестовых модельных данных. Произведено моделирование и оценка качества управления исходной системы управления, имеющей полную информацию о транспортном потоке (труднореализуемой на практике), а также системы управления, использующей совокупность данных, полученных с детекторов транспорта и при помощи нейросетевого прогнозирования. По результатам эксперимента система с нейросетевым прогнозом загруженности участков дороги по качеству управления отличается в среднем на 1,92 % по сравнению с идеализированной системой. Таким образом, данный способ можно считать применимым для использования в системах управления транспортными потоками на перекрестках.

Список источников:

1. Стрижко М.А., Червинский В.В. Применение нечеткой логики в системах интеллектуального управления светофорами // Информатика и кибернетика. – 2022. – №2 (28). – С. 5–10.
2. ОДМ 218.4.005-2010 Рекомендации по обеспечению безопасности движения на автомобильных дорогах. М.: Федеральное дорожное агентство (Росавтодор), 2011. 156 с.

References:

1. Strizhko M.A., Chervinsky V.V. Application of Fuzzy Logic in Intelligent Traffic Light Control Systems. Informatics and Cybernetics. 2022;2(28):5-10.
2. Recommendations for Ensuring Traffic Safety on Highways. Industry Road Guidance Document 218.4.005-2010. Moscow: Federal Road Agency (Rosavtodor); 2011.

3. Шилов А.В. Возможности и недостатки использования скользящей средней при выработке прогнозных решений // Приоритетные научные направления: от теории к практике. – 2015. – № 19. – С. 88-94.
4. Ostertagová E., Ostertag O. Forecasting using simple exponential smoothing method. *Acta Electrotechnica et Informatica*. 2012;12(3):62–66.
5. Поздняков А.С. Применение метода Хольта-Винтерса при анализе и прогнозировании динамики временных рядов // Проблемы организации и управления на транспорте: Сборник научных трудов студентов, магистрантов, аспирантов, молодых ученых и их научных руководителей (материалы межвузовской научно-практической конференции), Екатеринбург, 03 ноября 2016 года. Екатеринбург: Уральский государственный университет путей сообщения, 2017. – С. 57-64.
6. Емалетдинова Л.Ю., Кабиров А.Н., Вильданов Н.Р. Нейросетевое моделирование задачи прогнозирования значений временного ряда // Вестник Технологического университета. – 2022. – Т. 25. – № 10. – С. 101-106.
7. Дауб И.С. Обзор методов прогнозирования временных рядов с помощью искусственных нейронных сетей // StudNet. – 2020. – Т. 3. – № 10. – С. 247–257.
8. Мейзер М.В., Северьянова Е.Д., Мокшин В.В. Пример прогнозирования временных рядов с помощью рекуррентной нейронной сети LSTM // Молодой ученый. – 2022. – № 9 (404). – С. 13-15.
9. Яковлев В.Ф. Учебник по устройству легкового автомобиля. М.: «Третий Рим», 2008. 78 с.
10. Михалева Л.В., Алексеева О.В., Гасилова О.С., Сидоров Б.А. Результаты определения минимального безопасного расстояния между легковыми автомобилями, движущимися в попутном направлении // Известия Тульского государственного университета. Технические науки. – 2011. – № 4. – С. 214–219.
3. Shilov A.V. Possibilities and Disadvantages of Using a Moving Average When Developing Forecast Decisions. *Priority Scientific Directions: From Theory to Practice*. 2015;19:88-94.
4. Ostertagová E., Ostertag O. Forecasting Using Simple Exponential Smoothing Method. *Acta Electrotechnica et Informatica*. 2012;12(3):62-66.
5. Pozdnyakov AS. Application of the Holt-Winters Method in Analyzing and Forecasting the Dynamics of Time Series. In: *Proceedings of the Interuniversity Scientific-Practical Conference on Problems of Organization and Management in Transport*; 2016 Nov 03; Yekaterinburg: Ural State Transport University: 2017. p. 57-64.
6. Emaletdinova L.Yu., Kabirova A.N., Vildanov N.R. Neural Network Modeling of the Problem of Predicting the Values of the Time Series. *Bulletin of the Technological University*. 2022;25(10):101-106.
7. Daub I.S. Review of Methods for Forecasting Time Series Using Artificial Neural Networks. *StudNet*. 2020;3(10):247-257.
8. Meizer M.V., Severyanova E.D., Mokshin V.V. Example of Time Series Forecasting with LSTM Recurrent Neural Network. *Young Scientist*. 2022;9(404):13-15.
9. Yakovlev V.F. *A Textbook on the Passenger Car Construction*. Moscow: Third Rome; 2008.
10. Mikhaleva L.V., Alekseeva O.V., Gasilova O.S., Sidorov B.A. Results Determination of the Minimum Safety Distance, Passenger Cars Moving in the Same Direction. *Izvestiya Tula State University. Technical Sciences*. 2011;4:214-219.

Информация об авторах:

Стрижко Михаил Александрович
аспирант кафедры «Автоматика и телекоммуникации» Донецкого национального технического университета

Information about the authors:

Strizhko Mikhail Aleksandrovich
postgraduate student at the Department “Automation and Telecommunications” of Donetsk National Technical University

Статья поступила в редакцию 20.03.2024; одобрена после рецензирования 25.04.2024; принята к публикации 03.05.2024.

The article was submitted 20.03.2024; approved after reviewing 25.04.2024; accepted for publication 03.05.2024.

Рецензент – Малаханов А.А., кандидат технических наук, доцент, Брянский государственный технический университет.

Reviewer – Malakhanov A.A., Candidate of Technical Sciences, Associate Professor, Bryansk State Technical University.