

DOI: 10.51790/2712-9942-2024-5-4-17

РАЗРАБОТКА НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ УПРАВЛЕНИЯ СВЕТОФОРОМД. Д. Япаров^а, П. А. Бурьянов^б*Южно-Уральский государственный университет, г. Челябинск, Российская Федерация*^аORCID: <http://orcid.org/0000-0001-9106-2773>, ✉ iaparovdd@susu.ru^б buryanovp@list.ru

Аннотация: в настоящее время особо актуальной стала проблема светофорного регулирования транспортных потоков. Как правило, системы управления светофорами зависят от оператора или следуют строго прописанным заранее правилам. В связи с этим ставится задача разработки интеллектуальной системы, которая смогла бы полностью самостоятельно автоматически принимать решение о включении или выключении того или иного светофора на перекрестке. В работе рассмотрена модель городского светофора на крестообразном перекрестке. Предложены режимы работы перекрестка, характеризующиеся набором включенных и выключенных светофоров для безаварийного проезда машин в определенном направлении. Данные режимы позволяют свести задачу управления светофором к задаче классификации. Разработана нейросетевая модель светофора, позволяющая решить данную задачу. В качестве входных данных модель получает количество машин на каждом направлении. На выходе нейросетевая модель по создавшейся ситуации на перекрестке выбирает тот или иной режим перекрестка. Были проведены экспериментальные исследования для определения конфигурации модели, а также вычислительные эксперименты, показавшие принципиальную возможность использования данного подхода к решению поставленной задачи и высокую эффективность предложенной модели.

Ключевые слова: нейронные сети, обработка информации, «умный» светофор, управление транспортными потоками, стратегии обучения.

Для цитирования: Япаров Д. Д., Бурьянов П. А. Разработка нейросетевой модели для управления светофором. *Успехи кибернетики*. 2024;5(4):122–127. DOI: 10.51790/2712-9942-2024-5-4-17.

Поступила в редакцию: 03.10.2024.*В окончательном варианте:* 07.11.2024.**NEURAL NETWORK-BASED MODEL FOR TRAFFIC LIGHT CONTROL**D. D. Yaparov^а, P. A. Burianov^б*South Ural State University, Chelyabinsk, Russian Federation*^аORCID: <http://orcid.org/0000-0001-9106-2773>, ✉ iaparovdd@susu.ru^б buryanovp@list.ru

Abstract: traffic light regulation is a critical aspect of modern urban infrastructure. Traditional traffic light control systems rely on operators or predefined rules. We developed an intelligent system capable of independently and automatically managing traffic lights at an intersection. We modeled an urban traffic light system at a quad intersection and proposed their modes defined by sets of active and inactive traffic lights, ensuring the accident-free passage of vehicles. This reduces the traffic light control problem to a classification problem. We developed a neural network model for the traffic light system, which uses the number of vehicles in each direction as input and selects a traffic light mode to match the current traffic situation. We conducted experimental studies to determine the optimal model configuration. Our simulation experiments confirmed the feasibility of this approach and demonstrated the high efficiency of the proposed model.

Keywords: neural networks, information processing, smart traffic lights, traffic flow control, learning strategies.

Cite this article: Yaparov D. D., Burianov P. A. Neural Network-Based Model for Traffic Light Control. *Russian Journal of Cybernetics*. 2024;5(4):122–127. DOI: 10.51790/2712-9942-2024-5-4-17.

Original article submitted: 03.10.2024.*Revision submitted:* 07.11.2024.**Введение**

Одной из наиболее актуальных проблем крупных городов является проблема организации безопасного дорожного движения транспортных средств. Ключевой причиной возникновения данной проблемы являются несовершенные способы управления транспортными потоками. В связи с этим ставится задача разработки системы управления светофорами, которая позволит распоряжаться транспортными потоками, основываясь на данных, отражающих загруженность направлений перекрестка и дорог,

идущих от соседних с ним перекрестков. Перспективным направлением для решения этой задачи является разработка системы с помощью искусственных нейронных сетей [1]. Преимущество нейронных сетей заключается в возможности самообучения, что позволяет системе подстраиваться под изменяющуюся ситуацию на дороге, также данная система позволит получать статистические данные для городских служб с целью дальнейшего улучшения городской транспортной сети: изменения направления движения, расширения дороги и т. д. [2]. Новизна предлагаемого решения заключается в том, что система управления светофорами при принятии решений будет опираться на данные видеокamer на перекрестках.

Входные данные

В рамках данного исследования рассматривался перекресток пр. Ленина и ул. Энгельса г. Челябинска в дневное и вечернее время суток различных времен года. Данный перекресток имеет по три направления для каждой проезжей части, то есть поворот направо, движение прямо и поворот налево с возможностью разворота. Схема направления движения на перекрестке представлена на рисунке 1.




Рис. 1. Схема направления движения на перекрестке

Цифрами 1–12 обозначены направления движения, тогда входные данные для разрабатываемой системы можно представить в виде строки с количеством машин для каждого направления, где номер столбца соответствует номеру направления (табл. 1).

Для формирования входного набора данных видеозаписи с камеры на перекрестке обрабатывались с помощью нейронной сети на основе YOLOv8, в результате чего была сформирована выборка объемом 32400 записей (540 часов видео, не считая пустого времени) [3, 4].

Далее для каждого из направлений определили два режима: движение разрешено и запрещено (соответственно 1 и 0), тогда режимом перекрестка будем называть совокупность режимов для всех

Таблица 1

Пример записи входных данных

№ направления	1	2	3	4	5	6	7	8	9	10	11	12
Кол-во машин	5	8	6	0	3	11	2	3	9	6	7	1

направлений. В рамках нашего исследования было выбрано 4 режима перекрестка, исходя из условий не пересечения направлений движения и исключения даже «спорных» аварийных ситуаций, то есть, например, если разрешено движение по направлению 5, то движение по направлению 1 не допускается. Конфигурации режимов перекрестка приведены в таблице 2.

Таблица 2

Пример записи входных данных

№ направления	1	2	3	4	5	6	7	8	9	10	11	12
№ режима												
1	1	1	1	1	0	0	1	0	0	0	0	0
2	0	0	0	1	1	1	1	0	0	1	0	0
3	1	0	0	0	0	0	1	1	1	1	0	0
4	1	0	0	1	0	0	0	0	0	1	1	1

Построение и обучение нейронной сети

Выборка делилась на 3 компонента в следующем соотношении данных: обучающая — 70 %, тестовая — 20 % и валидационная — 10 %. Валидационная выборка используется для оценки качества работы сети.

В предлагаемой нейронной сети функционирование нейрона k представлено следующими уравнениями:

$$u_k = \sum_{m=1}^m \omega_{km} x_m, \quad Y_k = \varphi(u_k + b_k),$$

где x_1, x_2, \dots, x_m — входные сигналы; $\omega_{k1}, \omega_{k2}, \dots, \omega_{km}$ — синаптические веса нейрона k ; u_k — линейная комбинация входных воздействий; b_k — порог; φ — функция активации; Y_k — выходной сигнал нейрона.

Параметры $x_i, i = 1, \dots, 12$ являются количеством машин на каждом направлении и определяют входные данные для нейронной сети, а y является режимом перекрестка и результатом работы нейронной сети. Разработка структуры искусственной нейронной сети осуществлялась на основе экспериментальных исследований по концепциям, рассмотренным в работах [5–7].

В процессе формирования структуры сети рассматривались различные комбинации значений гиперпараметров, были рассмотрены 8 функций активации, такие как ReLu, Sigmoid, eLu, SeLu Linear, Softmax, exp. Также рассматривалось различное количество скрытых слоев от 1 до 10 с различным количеством нейронов от 12 до 60. В качестве стратегий обучения были выбраны градиентный спуск, обратное распространение ошибки и Adam.

Вычислительные эксперименты

Цель вычислительных экспериментов заключалась в построении нейросетевой модели с определенным набором гиперпараметров, позволяющим минимизировать значение функции потерь. В качестве функции потерь использовалась среднеквадратическая ошибка (MSE). Первый этап экспериментов связан с выбором наилучшей структуры нейронной сети. Комбинации гиперпараметров с минимальными значениями функции потерь приведены в таблице 3.

В результате экспериментальных исследований была сформирована структура нейронной сети: входной слой включает 12 нейронов с функцией активации Linear, 6 скрытых слоев из 23, 25, 19, 25, 17, 17 нейронов соответственно с функцией активации ReLU, выходной слой состоит из одного нейрона с функцией активации Linear. Оптимизатором сети является RMSProp.

Второй этап экспериментальных исследований предусматривал оценку качества работы нейронной сети [8–12], сформированной в результате первого этапа экспериментальных исследований.

Таблица 3

Результаты выбора структуры нейронной сети

Комбинации гиперпараметров	Значения функции потерь
Trial 14 summary Hyperparameters: activation: relu num_layers: 6 units_0: 23 units_1: 25 units_2: 19 units_3: 25 units_4: 17 units_5: 17 optimizer: RMSProp	0.08567003160715103
Trial 21 summary Hyperparameters: activation: tanh num_layers: 5 units_0: 23 units_1: 19 units_2: 15 units_3: 15 units_4: 25 optimizer: RMSProp	0.09008163213729858
Trial 02 summary Hyperparameters: activation: relu num_layers: 3 units_0: 25 units_1: 17 units_2: 23 optimizer: RMSProp	0.10416194796562195
Trial 04 summary Hyperparameters: activation: relu num_layers: 5 units_0: 15 units_1: 19 units_2: 21 units_3: 19 units_4: 15 optimizer: adam	0.10483033955097198
Trial 20 summary Hyperparameters: activation: relu num_layers: 4 units_0: 15 units_1: 17 units_2: 17 units_3: 23 optimizer: adam	0.11015956848859787

Показателем качества работы модели стало значение функции потерь. В экспериментах качество работы нейросети оценивалось при различных значениях количества эпох обучения. В результате наилучшая точность достигалась при 18 эпохах обучения. В таблице 4 приведены значения функции потерь относительно количества эпох обучения.

Таблица 4

Пример записи входных данных M

Количество эпох	Значения функции потерь
1	0,5100
2	0,1631
3	0,1177
4	0,1010
5	0,0957
6	0,0858
7	0,0741
8	0,0631
9	0,0559
10	0,0497
11	0,0533
12	0,0491
13	0,0412
14	0,0397
15	0,0353
16	0,0335
17	0,0325
18	0,0319
19	0,0415
20	0,0487

На валидационной выборке значение функции потерь составило 0.078, что свидетельствует о высокой точности предсказанных нашей моделью значений.

Заключение

В работе предложена нейросетевая модель управления переключением режимов светофоров по данным с видеокамер на перекрестке. Найдена оптимальная архитектура нейронной сети для задачи управления светофором. Полученная модель показала высокую точность как на обучающей и тестовой выборках, так и на валидационной.

ЛИТЕРАТУРА

1. Кадиленко Е. С., Тимофеева О. П. Определение оптимальной траектории движения транспортного средства на определённом участке карты. *Будущее технической науки: Сборник материалов XI Международной молодежной научно-технической конференции*. Нижний Новгород; 2012. С. 45–46.
2. Тимофеева О. П., Ермаков О. П., Туманова Д. Н. Модель системы «умных светофоров» на базе AnyLogic. *Будущее технической науки: Сборник материалов XV Международной молодежной научно-технической конференции*. Нижний Новгород; 2016. С. 115–116.
3. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*. 2017;60(6):84–90. DOI: 10.1145/3065386.
4. Russakovsky O., Deng J., Su H. ImageNet Large Scale Visual Recognition Challenge. *Int. J. of Computer Vision*. 2015;115(3):211–252. DOI: 10.1007/s11263-015-0816-y.
5. Круглов В. В., Борисов В. В. *Искусственные нейронные сети. Теория и практика*. М.: Горячая линия — Телеком; 2002. 382 с.
6. Каллан Р. *Основные концепции нейронных сетей*. М.: Издательский дом «Вильямс»; 2001. 287 с.

7. Рутковская Д., Пилиньский М., Рутковский Л. *Нейронные сети, генетические алгоритмы и нечеткие системы* / пер. с польск. И. Д. Рудинского. М.: Горячая линия — Телеком; 2006. 452 с.
8. Kingma D. P., Ba J. *Adam: A Method for Stochastic Optimization*. Режим доступа: <https://arxiv.org/abs/1412.6980>.
9. Goodfellow I., Bengio Y., Courville A. Deep Learning. *Genet Program Evolvable Mach.* 2018;19:305–307. DOI: 10.1007/s10710-017-9314-z.
10. Sutton R. S., Barto A. G. *Reinforcement Learning: An Introduction*. Cambridge: The MIT Press; 2014. 338 p.
11. Silver D., Huang A., Maddison C. J. Mastering the Game of Go with Deep Neural Networks and Tree Search. *Nature.* 2016;529:484–489. DOI: 10.1038/nature16961.
12. Kohavi R. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence.* 1995;2:1137–1143.