

Сравнение методов машинного обучения в задаче прогнозирования движения общественного транспорта

А.А. Агафонов¹, А.С. Юмаганов¹

¹Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

Аннотация. Задача прогнозирования движения общественного транспорта является одной из самых популярных задач в области транспортного планирования благодаря своей практической значимости. Для решения этой задачи применяются различные параметрические и непараметрические модели. В настоящей работе для прогнозирования движения используется разнородная информация, влияющая на величину прогноза, и приводится сравнение основных алгоритмов машинного обучения для прогнозирования времени прибытия общественного транспорта: модели нейронных сетей, регрессии методом опорных векторов. Экспериментальный анализ алгоритмов был проведен на реальных движениях о движении транспортных средств автобусных маршрутов в Самаре, Россия.

1. Введение

Городской пассажирский транспорт является важной частью транспортной системы. Эффективное использование пассажирского транспорта поможет снизить уровень дорожных заторов благодаря сокращению уровня использования личного автотранспорта, а также сократить расход топлива и снизить уровень загрязнения окружающей среды. Для повышения качества функционирования пассажирского транспорта необходимо в том числе предоставлять пассажирам информацию о точном прибытии транспортных средств на остановочные пункты. Эта информация имеет важное значение, поскольку позволяет пассажирам выбирать альтернативные маршруты движения и снизить время ожидания транспортных средств.

Время прибытия транспортных средств на остановочные пункты может рассматриваться как стохастическое, поскольку зависит от многих факторов, включая время прохождения дорожных сегментов, время пребывания на остановках и задержки на перекрестках. К тому же, для прогнозирования времени прибытия необходимо учитывать дорожные заторы, инциденты и погодные условия. Таким образом, разработка модели прогнозирования с учетом различных пространственно-временных факторов является сложной задачей.

Несмотря на популярность рассматриваемой задачи, многие работы рассматривают только отдельные факторы (например, скорость на текущем и предыдущем дорожных сегментах) для прогнозирования времени прибытия. Кроме того, сравнение алгоритмов проводится на различных наборах данных, зачастую составляющих данные о движении транспортных средств только одного или нескольких маршрутов.

В данной работе проводится сравнение моделей искусственной нейронной сети, метода опорных векторов и линейной регрессии для прогнозирования времени прибытия городского пассажирского транспорта на остановочные пункты. Для прогнозирования используется разнородная информация, описывающая транспортную ситуацию. Сравнение алгоритмов проводится на данных о движении транспортных средств автобусных маршрутов в г. Самаре, Россия.

2. Обзор литературы

Задаче прогнозирования движения пассажирского транспорта посвящено большое количество исследований. Существующие работы можно разделить на несколько категорий по типу используемых моделей и алгоритмов: параметрическая и непараметрическая регрессия, фильтрация Калмана, искусственные нейронные сети, метод опорных векторов, гибридные модели.

Модели линейной регрессии [1, 2] строятся как функции регрессии от набора независимых переменных. Применимость этих моделей для транспортных систем ограничена из-за сильной коррелированности переменных функции регрессии. Непараметрическая регрессия, в частности, метод k ближайших соседей, использовалась для решения задачи прогнозирования в работах [3, 4]. Однако требование большого размера выборки накладывает ограничение на использование этого метода в режиме реального времени. В [5] использовался алгоритм кластеризации для определения распределения времени прохождения дорожного сегмента.

Модели на основе фильтра Калмана [6] позволяют оценить будущие значения зависимых переменных на основе рекурсивной процедуры, учитывая стохастический характер процесса и шум измерений.

Модели искусственных нейронных сетей (ANN) [7, 8] являются наиболее часто используемым подходом для прогнозирования времени прибытия. В [7] объединены две модели нейронных сетей, обученные на наборе данных о прохождении дорожных сегментов и данных о времени прибытия транспортных средств на остановочные пункты. В работе [8] использовался байесовский подход для объединения нескольких нейронных сетей для построения прогноза. Сравнение моделей на основе архивных данных, моделей регрессии и модели нейронных сетей представлено в [9].

Метод опорных векторов в задаче регрессии (SVR) - набор схожих алгоритмов обучения с учителем, использующихся для задач классификации и регрессионного анализа [10, 11]. В работе [11] для прогнозирования использовалось время прохождения текущего и следующего сегментов. В [10] авторы использовали генетический алгоритм для выбора параметров SVR. В [12] использовались модель прогнозирования, объединяющая две модели SVR.

Для уменьшения ошибки прогноза также используются гибридные модели, объединяющие несколько разнородных методов и алгоритмов [13, 14, 15].

В [16] представлены результаты сравнения нескольких регрессионных моделей и методов машинного обучения, лучший результат был показан моделью SVR. Обратные результаты были получены в работе [17], лучшие результаты были показаны моделью нейронной сети. В большинстве работ лучшие результаты прогнозирования времени прибытия пассажирского транспорта были показаны с использованием методов машинного обучения: модели нейронной сети и SVR. Однако выбор конкретной модели зависит от используемых входных данных.

3. Основные обозначения и постановка задачи

Транспортную сеть будем рассматривать как ориентированный граф, вершины которого соответствуют остановкам, ребра - сегментам транспортной сети между остановками.

Введем следующие обозначения: s - остановка из множества S ; w_{ij} - сегмент транспортной сети между остановками $i \in S$ и $j \in S$ с длиной $|w_{ij}|$; r - маршрут пассажирского транспорта из множества R ; R_{ij} - множество маршрутов, проходящих по сегменту w_{ij} ; n - транспортное средство из множества N ; N_r - множество транспортных средств, выполняющих маршрут $r \in R$.

Задача прогнозирования времени прибытия транспортного средства $n \in N$ маршрута $r \in R$ на остановку $j \in S$ можно быть записана в виде:

$$t_j^{arr,n} = t_i^{dep,n} + T_{ij}^{travel,n}, \quad (1)$$

где $t_j^{arr,n}$ - время прибытия на остановку j , $t_i^{dep,n}$ - время отправления с остановки i , $T_{ij}^{travel,n}$ - время прохождения сегмента транспортной сети между остановками i и j .

Тогда задача прогнозирования времени прибытия сводится к задаче оценки времени прохождения сегментов дорожной сети $T_{ij}^{travel,n}$ или, что равноценно, скорости v_{ij}^n .

Формальная постановка задачи может быть записана в следующем виде: *имея заданный граф транспортной сети, а также статистические данные и данные реального времени о скорости прохождения сегментов транспортной сети, получить оценку скорости $\hat{v}_{ij}^n(t_c, t)$ в момент времени t , при условии, что оценка формируется в момент времени t_c .*

4. Предлагаемая модель

4.1. Факторы прогнозирования

Для получения оценки скорости \hat{v}_{ij}^n транспортного средства $n \in N$, выполняющего маршрут $r \in R$, могут учитываться различные факторы, влияющие на величину прогноза. В отличии от известных авторов работ, в данной статье предлагается использовать разнородную информацию, описывающую транспортную ситуацию. Состав искомой информации может быть определен следующим образом:

- v_{ij}^n - скорость прохождения сегмента w_{ij} транспортным средством $n \in N$;
- $v_{ij}^{route,r}$ - взвешенная средняя скорость прохождения сегмента w_{ij} транспортными средствами, выполняющими маршрут $r \in R$:

$$v_{ij}^{route,r}(t) = \frac{\sum_{k \in N_r} \omega(t - t_i^{dep,k}) v_{ij}^k}{\sum_{k \in N_r} \omega(t - t_i^{dep,k})},$$

где $\omega(t)$ - ядро

$$\omega(t) = \begin{cases} \exp(-\alpha t), & t \leq \Delta_{max}, \\ 0, & t > \Delta_{max}; \end{cases}$$

Δ_{max} - интервал времени, за который учитываются оценки скорости.

- v_{ij}^{all} - взвешенная средняя скорость прохождения сегмента w_{ij} транспортными средствами любого маршрута:

$$v_{ij}^{all}(t) = \frac{\sum_{r \in R_{ij}} \sum_{k \in N_r} \omega(t - t_i^{dep,k}) v_{ij}^k}{\sum_{r \in R_{ij}} \sum_{k \in N_r} \omega(t - t_i^{dep,k})},$$

- v^{hour} - скорость в транспортной сети, усредненная за час;
- v^{day} - скорость в транспортной сети, усредненная за день;

- $v_{ij}^{stat}(t)$ - средняя скорость прохождения сегмента w_{ij} транспортными средствами любого маршрута по статистическим данным в момент времени t ;
- $v_{ij}^{flow}(t)$ - средняя скорость транспортного потока на сегменте w_{ij} в момент времени t ;
- v_{ij}^{fNow} - скорость транспортного потока на сегменте w_{ij} в настоящий момент времени.

Предполагается, что средняя скорость за час и за день позволит косвенно учесть текущую сезонную и погодную ситуацию, средняя скорость транспортного потока - быстрее реагировать на изменение дорожной ситуации и возникновение заторов.

4.2. Базовая модель искусственной нейронной сети

В работе [17] в качестве модели прогнозирования использовалась модель нейронной сети с одним скрытым слоем, содержащим 5 нейронов. Для прогнозирования времени прохождения дорожного сегмента w_{ij} транспортным средством $n \in N$, выполняющим маршрут $r \in R$, использовались 3 фактора:

- взвешенная скорость прохождения сегмента тем же маршрутом $v_{ij}^{route,r}(t)$;
- взвешенная скорость прохождения сегмента любым маршрутом $v_{ij}^{all}(t)$;
- скорость движения транспортного средства на предыдущем сегменте $v_{i-1,i}^n$.

Обозначим эту модель как ANN^{3,5,1}.

4.3. Базовая модель метода опорных векторов

Метод опорных векторов (SVR) — это особый класс алгоритмов, который характеризуется использованием ядер. Наиболее распространенными ядрами являются линейное, полиномиальное, радиальная базисная функция, сигмоид. В работе используется радиальная базисная функция вида

$$k(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2),$$

где $\gamma > 0$ - параметр модели, \mathbf{x} и \mathbf{x}' - входные данные модели. В качестве входных данных используются 3 фактора, определенные в предыдущем подразделе.

4.4. Расширенная модель искусственной нейронной сети

Для оценки скорости $\hat{v}_{ij}^n(t_c, t)$ транспортного средства $n \in N$, выполняющего маршрут $r \in R$, предлагается использовать расширенную модель нейронной сети. Входные данные включают все описанные факторы прогнозирования, и могут быть записаны в виде вектора:

$$\mathbf{V} = \left(v_{i-1,i}^n, v_{ij}^{n1}, v_{ij}^{n2}, v_{ij}^{route,r}(t), v_{ij}^{all}(t), v_{ij}^{stat}(t_c), v_{ij}^{stat}(t), v_{ij}^{flow}(t_c), v_{ij}^{flow}(t), v^{hour}(t), v^{day}(t), v_{ij}^{fNow} \right).$$

где $n1$ - предыдущее транспортное средство маршрута r , прошедшее транспортный сегмент w_{ij} , $n2$ - предыдущее транспортное средство любого маршрута, прошедшее транспортный сегмент w_{ij} .

Для прогнозирования используется модель нейронной сети следующей структуры: один входной слой (12 нейронов), один скрытый слой (13 нейронов) и один выходной слой (1 нейрон). В качестве метода оптимизации был использован метод Adam [18].

5. Экспериментальные исследования

Экспериментальные исследования моделей проводились на данных о движении пассажирского транспорта автобусных маршрутов в транспортной сети г. Самары, Россия, за два месяца, с 1 августа 2018 по 30 сентября 2018. Прогноз выполнялся для 837 транспортных средств на 176 маршрутах.

Проводилось сравнение линейной регрессии LR, базовой модели нейронной сети ANN^{3,5,1} и метода опорных векторов SVR, расширенной модели нейронной сети ANN^{ext}. Для сравнения качества прогнозирования использовались две стандартные метрики: средняя абсолютная ошибка в процентах (MAPE) и средняя абсолютная ошибка (MAE).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|v_t - \hat{v}_t|}{v_t} \times 100\% \tag{2}$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |v_t - \hat{v}_t| \tag{3}$$

где v_t - фактическое значение скорости, \hat{v}_t - прогнозируемое значение.

В таблице 1 приведены результаты сравнения названных выше моделей прогнозирования для одного из маршрутов анализируемой транспортной сети.

Таблица 1. Сравнение моделей

	LR	ANN ^{3,5,1}	SVR	ANN ^{ext}
MAPE	29.58	29.76	34.75	27.75
MAE	1.76	1.77	2.20	1.60

В данном случае размер входных данных, используемых для обучения и прогнозирования, был ограничен данными о выбранном маршруте. Для прогнозирования использовались данные, полученные в заданный день, для обучения – все остальные. В таблице представлены средние значения MAE и MAPE, полученные для 7 дней. Из полученных результатов видно, что средняя величина ошибки прогноза для одного сегмента достаточно высока. Лучший результат демонстрирует расширенная модель искусственной нейронной сети.

Однако больший интерес представляют результаты прогнозирования времени прибытия транспорта на удаленные остановки. Для проведения экспериментальных исследований зависимости MAPE и MAE от горизонта прогноза был использован полный объем данных о движении транспортных средств. Исследования проводились для одного дня и всех маршрутов, при этом в качестве архивных данных использовались данные полученные за весь названный выше период времени за исключением выбранного дня. Для столь существенного объема входных данных время, затрачиваемое на обучение SVR модели, исчисляется десятками часов, а полученные выше результаты показывают превосходство других моделей, при проведении данных экспериментальных исследований SVR модель не использовалась. Графики зависимости MAPE и MAE от горизонта прогноза показаны на рисунке 1.

Исходя из полученных результатов, можно сделать вывод о том, что качество прогноза времени прибытия транспортного средства представленной в данной работе расширенной модели искусственной нейронной сети выше на всем горизонте прогноза, чем качество прогноза других рассмотренных моделей. Худший результат был получен при использовании базовой модели нейронной сети. При этом с увеличением значения величины горизонта прогноза уменьшается значение MAPE для всех рассмотренных моделей. Качество прогноза времени прибытия транспортного средства для удаленной остановки существенно выше, чем при прогнозе для ближайшего остановочного пункта.

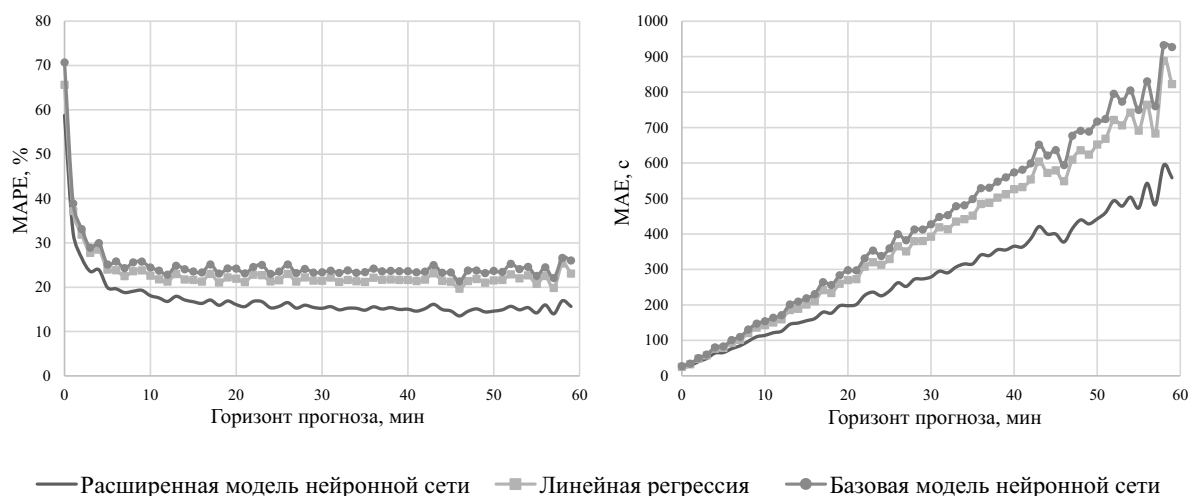


Рисунок 1. Зависимость MAPE и MAE от горизонта прогноза.

6. Заключение

В работе представлена расширенная модель нейронной сети, учитывающая разнородную информацию для прогнозирования времени прибытия пассажирского транспорта на остановки. В исследованиях, проведённых на данных движения городского пассажирского транспорта в г. Самаре, предложенный алгоритм прогнозирования показал лучший результат по сравнению с моделью линейной регрессии и базовыми моделями нейронной сети и методом опорных векторов.

Предложенная модель может использоваться для прогнозирования движения транспортных средств в режиме реального времени.

Дальнейшее направление работ включает в себя использование нескольких моделей регрессии для отдельных маршрутов или периодов дня.

7. Литература

- [1] Агафонов, А.А. Прогнозирование параметров движения городского пассажирского транспорта по данным спутникового мониторинга / А.А. Агафонов, А.В. Сергеев, А.В. Чернов // Компьютерная оптика. – 2012. – Т. 36, № 3. – С. 453-458.
- [2] Jeong, R. Prediction model of bus arrival time for real-time applications / R. Jeong, L. Rilett // Transportation Research Record. – 2005. – Vol. 1927. – P. 195-204. DOI: 10.3141/1927-23.
- [3] Chanh, H. Dynamic multi-interval bus travel time prediction using bus transit data / H. Chang, D. Park, S. Lee // Transportmetrica. – 2010. – Vol. 6(1). – P. 19-38. DOI: 10.1080/18128600902929591.
- [4] Smith, B. Comparison of parametric and nonparametric models for traffic flow forecasting / B. Smith, B. Williams, R. Keith Oswald // Transportation Research Part C: Emerging Technologies. – 2002. – Vol. 10(4). – P. 303-321. DOI: 10.1016/S0968-090X(02)00009-8.
- [5] Xu, H. Bus arrival time prediction with real-time and historic data / H. Xu, J. Ying // Cluster Computing. – 2017. – Vol. 20(4). – P. 3099-3106. DOI: 10.1007/s10586-017-1006-1.
- [6] Chen, M. A dynamic bus-arrival time prediction model based on APC data / M. Chen, X. Liu, J. Xia, S. Chien // Computer-Aided Civil and Infrastructure Engineering. – 2004. – Vol. 19(5). – P. 364-376. DOI: 10.1111/j.1467-8667.2004.00363.x.
- [7] Chien, S.-J. Dynamic bus arrival time prediction with artificial neural networks / S.-J. Chien, Y. Ding, C. Wei // Journal of Transportation Engineering. – 2002. – Vol. 128(5). – P. 429-438. DOI: 10.1061/(ASCE)0733-947X(2002)128:5(429).

- [8] van Hinsbergen, C. Bayesian committee of neural networks to predict travel times with confidence intervals / C. van Hinsbergen, J. van Lint, H. van Zuylen // *Transportation Research Part C: Emerging Technologies*. – 2009. – Vol. 17(5). – P. 498-509. DOI: 10.1016/j.trc.2009.04.007.
- [9] Jeong, R. Bus arrival time prediction using artificial neural network model / R. Jeong, L. Rilett. – 2004. – P. 988-993.
- [10] Yang, M. Bus arrival time prediction using support vector machine with genetic algorithm / M. Yang, C. Chen, L. Wang // *Neural Network World*. – 2016. – Vol. 26(3). – P. 205-217. DOI: 10.14311/NNW.2016.26.011.
- [11] Bin, Y. Bus arrival time prediction using support vector machines / Y. Bin, Y. Zhongzhen, Y. Baozhen // *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*. – 2006. – Vol. 10(4). – P. 151-158. DOI: 10.1080/15472450600981009.
- [12] Yu, B. Hybrid model for multi-stop arrival time prediction / B. Yu, Z.-Z. Yang, B. Yu // *Neural Network World*. – 2009. – Vol. 19(3). – P. 321-332.
- [13] Agafonov, A. Traffic flow forecasting algorithm based on combination of adaptive elementary predictors / A. Agafonov, V. Myasnikov // *Communications in Computer and Information Science*. – 2015. – Vol. 542. – P. 163-174. DOI: 10.1007/978-3-319-26123-2_16.
- [14] Yu, B. Hybrid model for prediction of bus arrival times at next station / B. Yu, Z.-Z. Yang, K. Chen, B. Yu // *Journal of Advanced Transportation*. – 2010. – Vol. 44(3). – P. 193-204. DOI: 10.1002/atr.136.
- [15] Zheng, W. Short-term freeway traffic flow prediction: Bayesian combined neural network approach / W. Zheng, D.-H. Lee, Q. Shi // *Journal of Transportation Engineering*. – 2006. – Vol. 132(2). – P. 114-121. DOI: 10.1061/(ASCE)0733-947X(2006)132:2(114).
- [16] Yu, B. Bus arrival time prediction at bus stop with multiple routes / B. Yu, W. Lam, M. Tam // *Transportation Research Part C: Emerging Technologies*. – 2011. – Vol. 19(6). – P. 1157-1170. DOI: 10.1016/j.trc.2011.01.003.
- [17] Yin, T. A prediction model of bus arrival time at stops with multi-routes / T. Yin, G. Zhong, J. Zhang // *Transportation Research Procedia*. – 2017. – Vol. 25. – P. 4627-4640. DOI: 10.1016/j.trpro.2017.05.381.
- [18] Adam: A Method for Stochastic Optimization [Electronic resource]. – Access mode: <https://arxiv.org/pdf/1412.6980.pdf> (15.10.2018).

Благодарности

Работа выполнена при частичной финансовой поддержке грантов РФФИ № 18-29-03135-мк, № 18-07-00605 А.

A comparison of machine learning methods for a bus arrival time prediction problem

A.A. Agafonov¹, A.S. Yumaganov¹

¹Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

Abstract. A public transport arrival time prediction problem is one of the most popular problems in the transportation planning field due to its practical importance. To solve this problem, various parametric and non-parametric models are used. In this work, to predict the arrival time, heterogeneous information is used that influences the prediction value. We provide a comparison of the machine learning algorithms to predict the bus arrival time, including neural networks models and support vector regression. An experimental analysis of the algorithms was carried out using real traffic data in Samara, Russia.