

УДК 004.051

Гавриков А. А., Свешникова С. Ю., Ганкевич И. Г.

Нейронные сети в задаче предсказания дорожного трафика

1. Введение. Жизнь современного города сложно представить без автомобилей, а жизнь современного мегаполиса — еще и без пробок. Это особенно критично для социально важных служб, таких как милиция, пожарная, скорая помощь, когда ценой некорректного выбора маршрута может стать чья-то жизнь. В этой области постоянно ведутся исследования, позволяющие увеличить скорость получения прогноза и его точность. Нет сомнений, что прогнозирование дорожного трафика еще долго будет оставаться одной из наиболее актуальных задач. Кроме общезвестных сервисов, например, «Яндекс.Пробки», есть много других проектов, также использующих предсказание трафика в контексте своей функциональности. Таким проектам часто приходится разрабатывать свои собственные пути решения этой задачи.

В данной работе решена задача о наиболее точном прогнозировании дорожного трафика с помощью нейронных сетей на основе данных для того же участка транспортной сети за несколько дней до этого. Необходимо определить, является ли данный подход уместным в этой задаче.

2. Оптимизация нейронной сети. Все изменения, проведенные в рамках исследования можно разделить на две части: начальная модель, изменение данных и изменение архитектуры. Кратко опишем ход работы для каждого из них.

2.1. Начальная модель. Исходные данные записаны в двух csv файлах. Первый содержит описание графа, представленное в виде списка ребер, второй — данные о загруженности каждого узла за период с 1 марта 0:00 до 20 апреля 8:00 с периодичностью пять минут.

Гавриков Антон Александрович — студент, Санкт-Петербургский государственный университет; e-mail: st047437@student.spbu.ru, тел.: +7(931)967-94-31

Свешникова Светлана Юрьевна — студент, Санкт-Петербургский государственный университет; e-mail: svetasvesh@yandex.ru, тел.: +7(812)428-47-83

Ганкевич Иван Геннадьевич — ассистент, Санкт-Петербургский государственный университет; e-mail: i.gankevich@spbu.ru, тел.: +7(812)428-47-83

Уровень пробки измеряется от 1 до 4, где 4 — максимальная загруженность дороги, а 1 — свободное движение по дороге. На основе этих данных требуется предсказать дорожный трафик 20 апреля с 8:00 до 10:00 с той же периодичностью. Обучение нейронной сети производится с помощью фреймворка PaddlePaddle. Для подсчета ошибки используется RMSE (Root Mean Squared Error) — среднеквадратичная ошибка модели:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}},$$

где y_i — значение, вычисленное по алгоритму, а \hat{y}_i — известное эталонное значение. В нашей задаче y_i — показатель загруженности дороги в момент времени i .

В качестве отправной точки для исследования будем использовать простейшую нейронную сеть с одним скрытым слоем. Данная нейронная сеть получает на вход данные за последние два часа одного узла и предсказывает загруженность дорог на следующие два часа с шагом в пять минут для этого же узла. Для тренировки программы использует два часа из разных промежутков времени за все 50 дней со всех узлов. Для каждого шага в предсказании, т. е. для каждого пяти минут, используется отдельная нейронная сеть.

2.2. Изменение данных. Простейшая нейронная сеть с одним скрытым слоем, запущенная на всех исходных данных, показала ошибку 0,68. Вместо того, чтобы обучать всю сеть, было решено обучать каждый узел независимо. Так как необходимо получить данные только для двух часов, с 8 до 10, то для обучения был взят промежуток с 6 до 12. Применение каждого из этих подходов не дало результата, но их совместное использование уменьшило ошибку на 0,08 до 0,60. Известно, что пробка на одном перекрестке может повлиять на дорожную обстановку на соседних перекрестках. Для учета такой ситуации вместо изначального значения узла в сеть подается его перевзвешенное значение, взятое с учетом значений в смежных узлах. Формула расчета нового уровня пробки для вершины:

$$\text{speed}[i] = \frac{1}{2} \left(\text{speed}[i] + \frac{\sum_{j=1}^k \text{speed}[j]}{k} \right),$$

где $i = \overline{1, n}$ — узлы, $j = \overline{1, k}$ — смежные узлы.

После этого был добавлен учет дня недели и обучение по последнему часу, а не двум, как это было ранее. Эти изменения совместно с перезвездом значений уменьшили ошибку до 0,56, при этом учет дня недели и обучение по последнему часу на исходных весах не дало результата. Для обучения нейронной сети самостоятельному перезвесу узлов подаются данные соседних узлов за один промежуток времени на каждый из 12 слоев, а данные о самом узле в отдельный слой. Далее все это обрабатывалось с помощью еще одного слоя и объединялось в слой из 12 нейронов (по количеству временных промежутков). Данный подход не дал положительных результатов. Основные идеи взяты из статьи [2].

2.3. Архитектура сети. В ходе исследования произведены следующие эксперименты с конфигурацией сети:

1. Изменение функции активации. Эта функция вычисляет значение выходного сигнала нейрона так, чтобы он находился в определенном промежутке (обычно от 0 до 1). Лучший результат показала *softmax* функция. Также были использованы функции *sigmoid*, *tanh* и *stanh*.
2. Выбор количества внутренних слоев сети от 1 до 3. Использование одного слоя наиболее оптимально. При увеличении количества слоев происходила потеря точности.
3. Использование рекуррентной модели (LSTM), которая считается наиболее предпочтительной для задач предсказания, но в нашем случае она показала ровно такой же результат. К недостаткам стоит отнести более сложный процесс настройки, по сравнению с обычной сетью [1, 3].
4. Изменение количества нейронов в одном слое от 6 до 200. Наилучший результат был достигнут при значении 64.

2.4. Окончательная версия. Таким образом, наилучший результат продемонстрировала нейронная сеть с одним скрытым слоем, которая предсказывает и тренируется отдельно для каждого узла, используя лишь тот день недели, на который формируется предсказание и промежуток времени с 6 до 12. Предсказание формируется на основе данных за полтора часа.

Таблица 1. Влияние изменений на значение ошибки

Начальная ошибка	0.68
Использование своей нейронной сети для каждого узла	0.68
Период обучения с 6 до 12	0.68
Предыдущие два пункта вместе	0.6
Рекуррентная сеть	0.6
Перевзвес узлов	0.6
Обучение по одному дню в неделю	0.58
Использование одного часа вместо двух часов для обучения	0.56

3. Заключение. Получено увеличение точности прогноза после изменения формата начальных данных. Изменение и усложнение архитектуры сети не повлияло на точность прогноза. Тем не менее, использование более сложных моделей сети это единственный способ добиться более точных результатов, но в данной работе не удалось подобрать оптимальную архитектуру сети для описанной задачи. Хорошим подходом будет комбинирование различных архитектур. Отметим, что используется RMSE для подсчета ошибки в рассмотренной задаче, но данный подход не дает реального представления о том, насколько различна ситуация на дороге. Таким образом, в дальнейшем следует найти или разработать другой способ подсчета ошибки, так как этот не удовлетворяет данной задаче в полной мере. При использовании другого метода подсчета ошибки рекуррентная модель может дать более точные результаты. Также стоит объединить рекуррентную модель и пересчет весов с помощью нейронной сети и узнать, как это повлияет на результат предсказания.

Литература

1. Yisheng Lv, Yanjie Duan, Wenwen Kang et al. Traffic flow prediction with big data: a deep learning approach // IEEE Transactions on Intelligent Transportation Systems. 2015. No 2. P. 865–873.
2. Пупырев С., Пронченков А. Прогнозирование загруженности автомобильных дорог // IV Российская летняя школа по информационному поиску RUSSIR'2010. Воронеж. 2010. С. 64–78.
3. Yasdi R. Prediction of road traffic using a neural network // Neural computing and applications. 1999. No 2. P. 135–142.