

УДК 004.942

DOI 10.51691/2541-8327_2023_1_6

***ИССЛЕДОВАНИЕ МЕТОДА ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ
РЯДОВ НА ТРАНСПОРТЕ С ПОМОЩЬЮ РЕКУРРЕНТНЫХ
НЕЙРОННЫХ СЕТЕЙ***

Лысов Г.М.

Ассистент,

*Федеральное государственное автономное образовательное учреждение
высшего образования «Российский университет транспорта»,*

Москва, Россия

Приходько Ф.Н.

Студент,

*Федеральное государственное автономное образовательное учреждение
высшего образования «Российский университет транспорта»,*

Москва, Россия

Коновалова А.А.

Студент,

*Федеральное государственное автономное образовательное учреждение
высшего образования «Российский университет транспорта»,*

Москва, Россия

Тимошенко К.А.

Студент,

*Федеральное государственное автономное образовательное учреждение
высшего образования «Российский университет транспорта»,*

Москва, Россия

Аннотация

Для эффективного планирования ресурсов, необходимых для реализации проектов и решений в сфере транспорта, важно точно определять
Дневник науки | www.dnevniknauki.ru | СМН ЭЛ № ФС 77-68405 ISSN 2541-8327

перспективные показатели деятельности транспортных объектов (пассажиропоток, грузопоток и т.д.). Составить точный прогноз позволяет прогнозирование временных рядов с помощью рекуррентных нейронных сетей. В статье рассмотрены три модели прогнозирования: ARIMA, LSTM, PROPHET. Определены преимущества и недостатки каждой модели.

Ключевые слова: прогнозирование временных рядов, рекуррентные нейронные сети, пассажиропоток, ARIMA, LSTM, PROPHET, алгоритмы прогнозирования, прогноз данных.

RESEARCH ON METHODS OF FORECASTING TIME SERIES IN TRANSPORT USING RECURRENT NEURAL NETWORKS

Lysov G.M.

Asistent,

*Federal State Institution of Higher Education «Russian University of Transport»,
Moscow, Russia*

Prikhodko F.N.

Student,

*Federal State Institution of Higher Education «Russian University of Transport»,
Moscow, Russia*

Konovalova A.A.

Student,

*Federal State Institution of Higher Education «Russian University of Transport»,
Moscow, Russia*

Timoshenko K.A.

Student,

*Federal State Institution of Higher Education «Russian University of Transport»,
Moscow, Russia*

Abstract

To effectively plan the resources needed to implement projects and decisions in the field of transport, it is important to accurately determine the future performance of transportation facilities (passenger traffic, freight flow, etc.). Time series forecasting with the help of recurrent neural networks allows making accurate forecasts. This article considers three forecasting models: ARIMA, LSTM, PROPHET. The advantages and disadvantages of each model are determined.

Keywords: time series forecasting, recurrent neural networks, passenger flow, ARIMA, LSTM, PROPHET, forecasting algorithms, data forecasting.

Введение

В современных условиях развития транспортной отрасли для определения планируемого количества ресурсов, необходимых для реализации краткосрочных и долгосрочных решений, усиливается потребность в использовании метода прогнозирования. Данный метод позволяет планировать ситуацию на объектах транспортной инфраструктуры, а в дальнейшем в комплексе с другими методами определять необходимость в модернизации линейных объектов транспорта и разрабатывать решения по их оптимизации.

Ограниченное количество данных и сложность их получения подтверждают необходимость использования прогнозирования в различных областях сферы транспорта и не только. [1]

Цель и методы исследования

Целью исследования является поиск наилучшей архитектуры для решения задач по прогнозированию пассажиропотоков рекуррентными нейронными сетями. В качестве метода исследования используется сравнение трех вариантов архитектуры на основе чего делается вывод.

Основная часть

Реализация метода предполагает: выбор параметра, по которому будет производиться прогнозирование; сбор имеющихся данных о прошедших событиях; определение математической модели; прогноз и определение выводимых данных, с учётом ошибки, а также формирование выводов.

Исходя из области применения, параметр прогноза может быть различным. Для планирования эксплуатационной ситуации городского транспорта необходимо знать, какое количество пассажиров воспользуется тем или иным объектом в определённом периоде, а в сфере грузовых железнодорожных перевозок необходимо определять планируемый грузопоток по направлениям.

Существует несколько методов прогнозирования временных рядов. Рассмотрим прогнозирование с помощью рекуррентных нейронных сетей на примере моделей ARIMA, LSTM, PROPHET.

Описание архитектуры ARIMA

ARIMA (англ. autoregressive integrated moving average) – это интегрированная модель авторегрессии – скользящего среднего – методология анализа временных рядов. [2] Является расширением моделей ARMA для нестационарных временных рядов, которые можно сделать стационарными взятием разностей некоторого порядка от исходного временного ряда (так называемые интегрированные – разностно-стационарные временные ряды). [5]

Модель ARIMA для нестационарного временного ряда имеет вид:

$$\Delta^d X_t = c + \sum_{i=1}^p a_i \Delta^d X_{t-1} + \sum_{j=1}^q b_j e_{t-j} + e_t$$

В сезонных ARIMA моделях выделяют также параметры (p, d, q) (P, D, Q)_m, где p – это показатель сезонности, d – показатель степени различия, q – показатель шума данных (степени модели скользящей средней) P_m, D_m, Q_m – правила авторегрессии, разности и скользящего среднего. [4]

Метод прогнозирования модели ARIMA на первом этапе оценивает статичность ряда. Разнообразными способами проверяется наличие единичных корней и порядок интегрированности использованных данных (как правило это число составляет от 1 до 2). Следующим этапом является преобразование ряда способом взятия разности используемого порядка. Далее для реорганизованной модели создаётся соответствующая ARMA-модель, так как подразумевается, что составленный процесс является статичным, в отличие от изначального переменного процесса. [3]

Описание архитектуры LSTM

LSTM (англ. long short-term memory) – продолжительная цепочка компонентов краткосрочной памяти, вариант организации рекуррентных нейронных сетей. [6]

В стандартном формате, LSTM включает в себя позиции, входного шлюза, выходного шлюза и шлюза забывания. Позиции не изменяют содержание на обусловленных временных промежутках, одновременно с этим шлюзы управляют массивом входных и выходных данных. [7]

В стандартной форме, модель возможно представить через систему уравнений:

$$\begin{aligned}f_t &= \sigma_g(W_f x_t + U_f c_{t-1} + b_f) \\f_t &= \sigma_g(W_i x_t + U_i c_{t-1} + b_i) \\f_t &= \sigma_g(W_o x_t + U_o c_{t-1} + b_o) \\c_t &= f_i o c_{t-1} + i_t o \sigma_c(W_c x_t + b_c) \\h_t &= o_t o \sigma_h(c_t),\end{aligned}$$

где x_t – входной вектор, h_t – выходной вектор, c_t – вектор состояний, W , U и b – матрицы параметров и вектор «предвзятости», которые получаются в ходе обучения, f_t – вектор активации шлюза забывания, i_t – вектор активации шлюза ввода/обновления данных, o_t – вектор активации шлюза вывода данных.

Описание архитектуры PROPHET

Prophet (англ. пророк) - это операция прогнозирования временных рядов, построенная на совокупной модели, в составе которой тенденции, имеющие нелинейную последовательность, сочетаются с ежегодной, недельной и ежедневной сезонностью, а также воздействием от праздничных дней. Модель отлично подходит к данным, которые обладают высокой сезонностью и некоторое количество циклов, полученных ранее данных. Prophet стабилизирован к недостающим данным и не чувствителен к изменениям в тренде, а также, как правило, отлично преодолевает скачки значений. [8]

Prophet использует разложимую модель временных рядов с тремя основными компонентами модели: тренд, сезонность и праздники.

Подобно обобщенной аддитивной модели (GAM), со временем в качестве регрессора, Prophet соответствует нескольким линейным и нелинейным функциям времени в качестве его компонентов.

$$y(t) = g(t) + s(t) + h(t) + e(t);$$

где $g(t)$ – тренд (функция неперiodических изменений (т.е. рост с течением времени); $s(t)$ – сезонность (функция периодических изменений (т.е. еженедельные, ежемесячные, ежегодные); $h(t)$ – функция, учитывающая праздничные дни; $e(t)$ – функция, охватывающая специфические изменения, не учитываемые моделью.

В качестве входных данных была использована информация о пассажиропотоке станции Коптево Московского метрополитена в период с января 2017 года по декабрь 2019 года. Принцип использования данных состоит в разделении информации на две части: тренировочная часть (используется для обучения программы и составляет от 70 до 85 процентов) и тестовая часть (используется для сравнения построенного прогноза с реальными данными).

Результаты

Рассмотрим прогноз, составленный с помощью модели ARIMA (рисунок 1), модели LSTM (рисунок 2) и модели PROPHET (рисунок 3).




Рис. 1 - Демонстрация работы модели ARIMA¹





Рис. 2 - Демонстрация работы модели LSTM²

¹ Составлено автором по результатам прогнозирования модели ARIMA

² Составлено автором по результатам прогнозирования модели LSTM

Рис. 3 - Демонстрация работы модели PROPHET³

Исходя из трёх графиков, можно сделать вывод, что каждая модель в достаточной степени справилась со своей задачей и значения прогнозируемого и реального пассажиропотока близки, а также среднеквадратическая ошибка не превышает десяти процентов (таблица 1). Наибольшие отклонения видимы в местах пиковых значений и на участках резкого спада или подъема.

Таблица 1 - Сравнение точности расчета моделей

Модель	ARIMA	LSTM	PROPHET
Среднеквадратическая ошибка (RMSE)	46 691,33 (9,4%)	29 199,83 (5,3%)	13 235,97 (2,4%)
Средняя абсолютная ошибка (MAE)	38 332,55 (7,6%)	22 941,17 (4,1%)	12 014,88 (2,2%)

Скорость расчёта прогноза и показателей в среднем составила:

- Для модели ARIMA – 19,7 секунд;
- Для модели LSTM – 28,9 секунд;
- Для модели PROPHET – 15,5 секунд.

Заключение

Все три метода прогнозирования показали достаточно высокую точность, однако оптимальным выбором в пользу скорости и минимальной

³ Составлено автором по результатам прогнозирования модели PROPHET

ошибки будет PROPHET. Использование модели ARIMA быстро, но значения реального и прогнозируемого пассажиропотока разнятся в большей степени из прогнозов исследуемых моделей, это обусловлено высоким требованиям к числу входящих данных. Преимуществом LSTM является возможность связывать предыдущую информацию с текущей задачей (т.е. сохранение знания о предыдущем значении помогает в понимании текущего значения).

При расчёте потребного числа ресурсов и определении необходимости модернизации объектов транспортной инфраструктуры применение метода прогнозирования временных рядов даёт возможность оперативной разработки результативных решений. Данная методика прогнозирования способствует внедрению нейронных сетей в транспортную отрасль и упрощает планирование эксплуатационных событий.

Библиографический список:

1. Плахотников, Д. П. Способы прогнозирования параметров киберфизических систем / Д. П. Плахотников // Международная научная конференция по проблемам управления в технических системах. – 2021. – Т. 1. – С. 294-297. – EDN LPLWCT.
2. Якимов, М. А. Сравнительное тестирование моделей ARIMA и LTSM в задачах прогнозирования пассажиропотока / М. А. Якимов, К. В. Операйло, Е. Н. Новикова // Символ науки: международный научный журнал. – 2022. – № 6-2. – С. 29-33. – EDN NXQJPC.
3. Якимов М.А., Операйло К.В., Новикова Е.Н. СРАВНИТЕЛЬНОЕ ТЕСТИРОВАНИЕ МОДЕЛЕЙ ARIMA И LTSM В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ ПАССАЖИРОПОТОКА // Символ науки. 2022. №6-2. URL: <https://cyberleninka.ru/article/n/sravnitelnoe-testirovanie-modeley-arima-i-ltsm-v-zadachah-prognozirovaniya-passazhiropotoka> (дата обращения: 29.01.2023).

4. Felix A. Gers; Jürgen Schmidhuber; Fred Cummins (2000). "Learning to Forget: Continual Prediction with LSTM". // Neural Computation., p. 2451–2471
5. Hyndman, Rob J; Athanasopoulos, George. 8.9 Seasonal ARIMA models. Forecasting principles and practice. oTexts. [Электронный ресурс]. — Режим доступа — URL: <https://otexts.com/fpp2/seasonal-arima.html> (Дата обращения 29.01.2023)
6. "Notation for ARIMA Models". Time Series Forecasting System. SAS Institute. [Электронный ресурс]. — Режим доступа — URL: <https://dms.umontreal.ca/~duchesne/chap7.pdf> (Дата обращения 29.01.2023)
7. Robson, Winston A. "The Prophet on Walmart — Comprehensive Intro to FbProphet." [Электронный ресурс]. — Режим доступа — URL: <https://medium.com/future-vision/intro-to-prophet-9d5b1cbd674e> (Дата обращения 29.01.2023).
8. Sepp Hochreiter; Jürgen Schmidhuber. Long short-term memory // Neural Computation journal. — 1997. — Vol. 9, no. 8. — P. 1735—1780

Оригинальность 97%