

**Список использованной литературы:**

1. Чернов А.Н., Агапитов Е.Б. Методика размещения кондиционеров в центрах обработки данных для обеспечения эффективного охлаждения ИТоборудования. // Журнал Естественные и технические науки. Строительство и архитектура. – 2011. – №6. – С.611-613
2. Вишневский Е.П. Микроклиматическое обеспечение цод / Вишневский Е.П., Салин М.Ю., Толоконников Т.Р. // Сантехника, Отопление, Кондиционирование (С.О.К.) — 2010. — № 5. — С. 72–75
3. Kurkjian C., Glass J. Проектирование систем кондиционирования ЦОД (перевод из ASHRAE Journal) // Мир Климата. – 2007. – №44
4. Veap J. Энергетически эффективные центры обработки данных (ЦОД). Техническое решение с совмещенными рядами (перевод из ASHRAE Journal) // Мир Климата. – 2009. – №53
5. Колосницын А. Н., Денисихина Д. М. Использование программы STAR-ССМ+ при проектировании систем вентиляции: учеб. пособие / А.Н. Колосницын, Д.М. Денисихина. СПб.: СПбГАСУ, 2016. – 100 с

© Ильин Е.А., Зеленина В.А., 2022

**УДК 62**

**Якимов М.А.**

студент 1-го курса аспирантуры  
Северо-Кавказского федерального университета  
Россия, г. Ставрополь

**Операйло К.В.**

студент 1-го курса аспирантуры  
Северо-Кавказского федерального университета  
Россия, г. Ставрополь

**Новикова Е.Н.**

кандидат физико-математических наук  
доцент кафедры информационных технологий и телекоммуникаций  
Северо-Кавказского федерального университета  
Россия, г. Ставрополь

**Научный руководитель: Дроздова В.И.**

доктор физико-математических наук  
профессор кафедры информационных систем и технологий  
Северо-Кавказского федерального университета  
Россия, г. Ставрополь

**СРАВНИТЕЛЬНОЕ ТЕСТИРОВАНИЕ МОДЕЛЕЙ ARIMA И LTSM В ЗАДАЧАХ  
ПРОГНОЗИРОВАНИЯ ПАССАЖИРОПОТОКА**

**Аннотация**

Чтобы удовлетворить потребность в общественном транспорте в реальном времени, автобусным операторам необходимо вовремя корректировать расписание. Следовательно, необходимо прогнозировать вариации краткосрочного пассажиропотока. В статье рассматривается реализация и

сравнение двух возможных методов прогнозирования, ARIMA и LTSM.

**Ключевые слова:**

ARIMA, прогнозирование пассажиропотока, алгоритмы прогнозирования, искусственные нейронные сети, LTSM.

**Введение**

Ключевым параметром при составлении расписания общественного транспорта является анализ и сбор информации о пассажиропотоке. В зависимости от количества пассажиров на отдельных остановках в разные отрезки времени, возможно выделение различного количества транспортных средств. Однако, подобные данные достаточно затруднительны в сборе. В условиях ограниченного количества данных о пассажирах поднимается задача прогнозирования пассажиропотока на основе уже собранных исторических параметров.

Существует несколько различных подходов к решению подобной задачи, в ходе данного исследования были выбраны методы ARIMA и LSTM- сетей.

**Обзор архитектуры ARIMA**

**ARIMA** (англ. *autoregressive integrated moving average*) – это интегрированная модель авторегрессии – скользящего среднего - модель и методология анализа временных рядов. Является расширением моделей ARMA для нестационарных временных рядов, которые можно сделать стационарными взятием разностей некоторого порядка от исходного временного ряда (так называемые интегрированные или разностно-стационарные временные ряды).[1]

Модель Адля нестационарного временного рядаимеет вид:

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

В сезонных ARIMA моделях выделяют также параметры ARIMA (p, d, q)(P, D, Q)<sub>m</sub>,

Где p – это сезонность (порядок авторегрессивной модели),

d – степень различия

q – шум данных (степень модели скользящей средней)

P,D,Q – условия авторегрессии, разности и скользящего среднего. [2]

В нашем случае, используются параметры ARIMA(1,1,1) (1,1,0,12).

Подход ARIMA к временным рядам заключается в том, что в первую очередь оценивается стационарность ряда. Различными тестами выявляются наличие единичных корней и порядок интегрированности временного ряда (обычно ограничиваются первым или вторым порядком). Далее при необходимости (если порядок интегрированности больше нуля) ряд преобразуется взятием разности соответствующего порядка и уже для преобразованной модели строится некоторая ARMA-модель, поскольку предполагается, что полученный процесс является стационарным, в отличие от исходного нестационарного процесса (разностно-стационарного или интегрированного процесса). [3]

**Обзор LTSM**

**Long Short-Term Memory (LTSM)** - длинная цепь элементов краткосрочной памяти, разновидность архитектуры рекуррентных нейронных сетей, предложенная в 1997 году Зеппом Хохрайтером и Юргеном Шмидхубером. [4]

В обычном виде, LSTM состоит из ячейки, входного шлюза, выходного шлюза и шлюза забывания. Ячейки сохраняют значения на условных временных интервалах, в то время как три шлюза регулируют поток входной и выходной информации. [5]

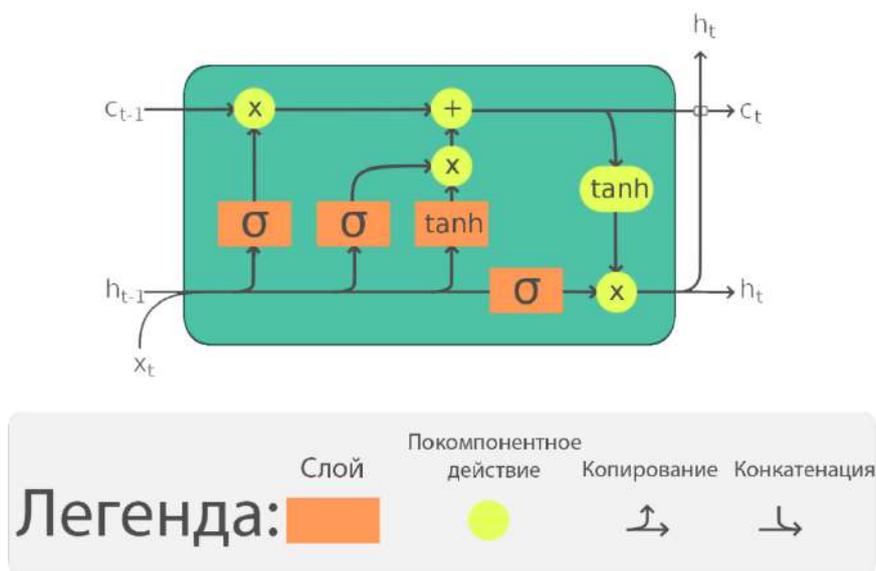


Рисунок 1 – Общая структура LSTM

В общем виде, сеть можно представить системой уравнений:

$$f_t = \sigma_g(W_f x_t + U_f c_{t-1} + b_f) \tag{2}$$

$$i_t = \sigma_g(W_i x_t + U_i c_{t-1} + b_i) \tag{3}$$

$$o_t = \sigma_g(W_o x_t + U_o c_{t-1} + b_o) \tag{4}$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \sigma_c(W_c x_t + b_c) \tag{5}$$

$$h_t = o_t \circ \sigma_h(c_t) \tag{6}$$

где  $x_t$  – входной вектор,

$h_t$  – выходной вектор, так же известный как скрытый 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.

В качестве входных данных для моделей были использованы данные о пассажиропотоке на отдельной остановке в течении 12 дней. Данные были разделены на две части, одна из которых использовалась для обучения моделей. На основе введенных исторических данных формировался прогноз, который затем сравнивался с «истинным» значением для определения точности прогноза.

Рассмотрим прогнозируемые данные на основе одного дня:

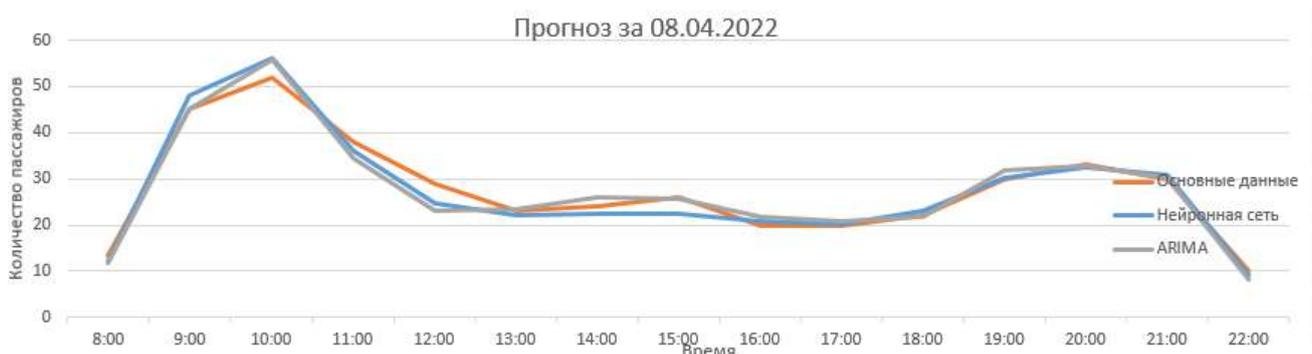


Рисунок 2 – График сопоставления двух систем

Как можно заметить, обе модели в значительной степени верно предсказали трэнд изменения пассажиропотока с течением времени. Наибольшие отклонения с наблюдаемыми данными произошли в пиковых значениях, а также в переходных сегментах, на участках резкого изменения от большего к меньшему.

В общем виде, наблюдаемая тенденция сохраняется и в других рассматриваемых днях.

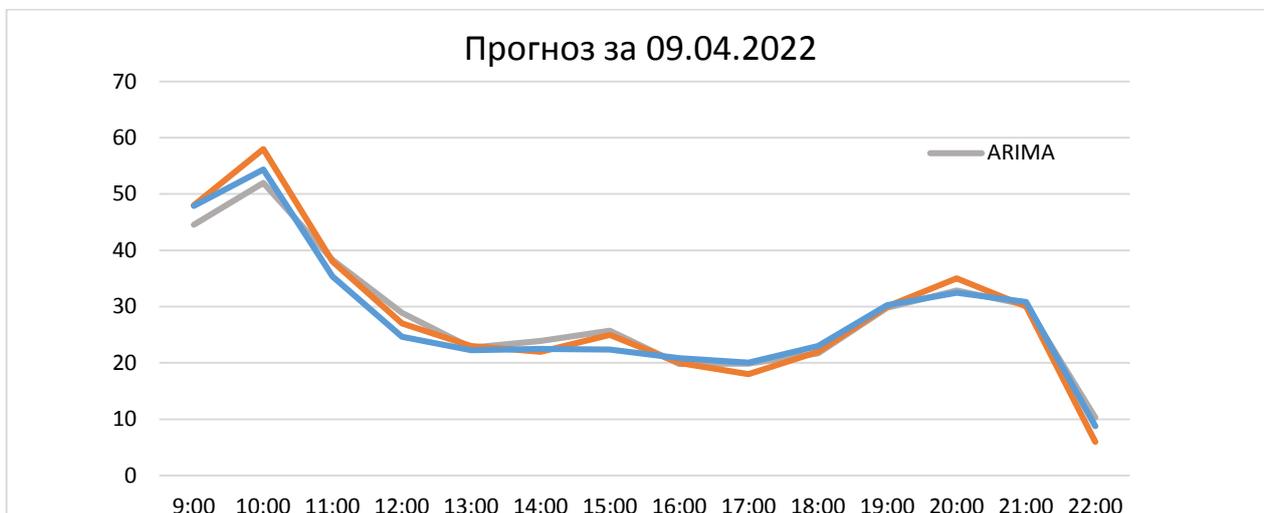


Рисунок 3 – Прогнозирование на другой день

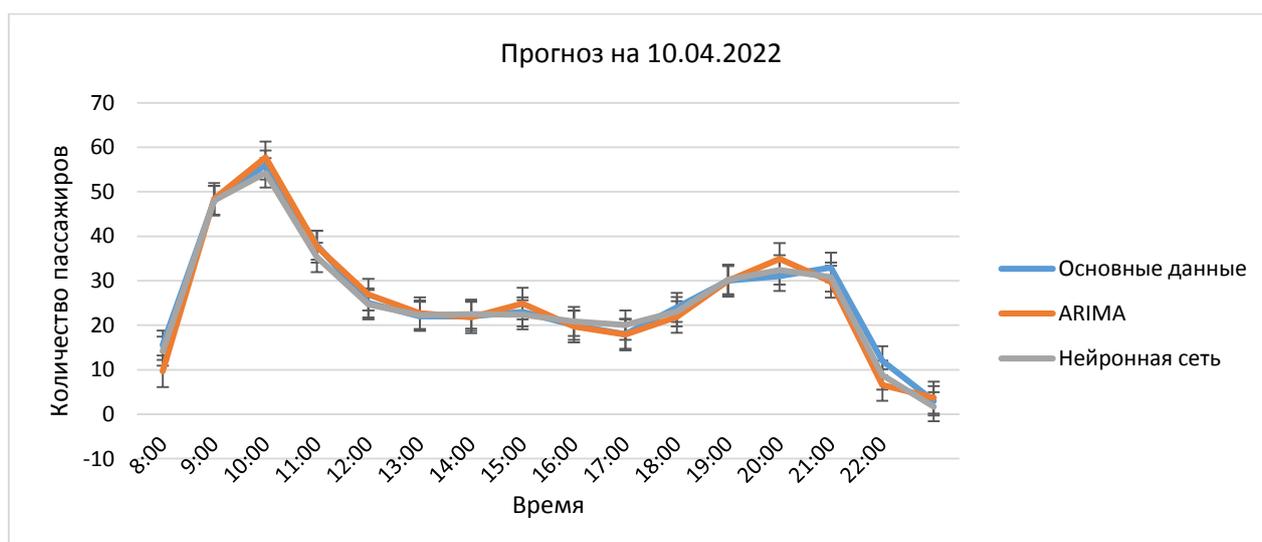


Рисунок 4 – Сравнение отклонений от реальной величины

На рисунке 4 представлен график сравнения двух моделей предсказания. Как можно заметить, наибольшие отклонения появляются в случаях резкого перехода от низкого к большому значению – или наоборот. В целом, и тот и другой метод показывают достаточно высокую точность прогнозирования.

Среднеквадратическая ошибка для моделей составляет:

- 1) ARIMA:  $S_x = 6,2484$
- 2) LTSM:  $S_x = 3,8764$

В свою очередь, среднеквадратическое отклонение составляет:

- 1) ARIMA:  $RMSE = 2,4996$
- 2) LTSM:  $RMSE = 1,9668$

Оба метода показывают высокую точность в прогнозировании, с нейронной сетью, выдающей чуть

более точный результат.

Плюсом метода ARIMA является скорость вычисления, в то время как LSTM выдает более точный прогноз.

#### **Заключение**

При оптимизации расписания общественного транспорта крайне важно учитывать пассажиропоток, а в задачах сбора информации о пассажиропотоке возможна имплементация его прогнозирования. В статье были рассмотрены два вида алгоритмов, а также проведен их сравнительный анализ.

#### **Список использованной литературы:**

1. Hyndman, Rob J; Athanasopoulos, George. 8.9 Seasonal ARIMA models. Forecasting principles and practice. oTexts. Retrieved 19 May 2015 // <https://otexts.com/fpp2/seasonal-arma.html>
2. "Notation for ARIMA Models". Time Series Forecasting System. SAS Institute. Retrieved 19 May 2015.
3. ARIMA. Основные представления. Возможности применения // <https://students-library.com/library/read/19711-arma-osnovnye-predstavlenia-vozmoznosti-primeneniia>
4. Sepp Hochreiter; Jürgen Schmidhuber. Long short-term memory // Neural Computation journal. — 1997. — Vol. 9, no. 8. — P. 1735—1780
5. Felix A. Gers; Jürgen Schmidhuber; Fred Cummins (2000). "Learning to Forget: Continual Prediction with LSTM". // Neural Computation., p. 2451–2471

© Якимов М.А., Операйло К.В., Новикова Е.Н., 2022