

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

УДК 004.032.26

ИССЛЕДОВАНИЕ МЕТОДОВ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ПРИРОДНОГО ГАЗА КЛИЕНТАМИ ОАО «ГАЗПРОМ ТРАНСГАЗ БЕЛАРУСЬ»

Д. М. ВАСИЛЬЕВА

(Представлено: д-р техн. наук, доц. Р. П. БОГУШ)

Рассматривается реализация методов прогнозирования потребления природного газа клиентами ОАО «Газпром Трансгаз Беларусь». Показаны результаты экспериментов по поиску наиболее эффективной структуры нейронной сети долгой краткосрочной памяти LSTM для снижения количества потерь при прогнозировании потребления природного газа. Представлен анализ результатов исследований точности прогнозирования при помощи трех методов прогнозирования: метод Хольта-Винтерса, LSTM и ARIMA.

Введение. Газораспределительные сети являются сложными техническими системами и включают большое число средств телеметрии и телемеханики для контроля параметров, необходимых для надежного функционирования и обеспечения безопасности процесса транспортировки газа, и уменьшение затрат, связанных с техническим обслуживанием газотранспортной системы. При этом прогнозирование потребления природного газа является важным инструментом, так как это необходимо для оптимизации режимов его транспортировки.

За последнее время интерес научной общественности к исследованию и применению нейронных сетей сильно возрос, об этом свидетельствуют многочисленное количество научных публикаций. Это обусловлено многочисленными областями применения, основными из которых являются: прогнозирование, принятие решений, распознавание образов, оптимизация, анализ данных.

Целью данной работы является поиск максимально эффективного метода решения задачи прогнозирования потребления природного газа клиентами ОАО «Газпром Трансгаз Беларусь».

С использованием анализа работ [1] было спрогнозировано потребление природного газа при помощи метода Хольта-Винтерса, построена модель нейронной сети долгой краткосрочной памяти LSTM с максимально эффективными параметрами и проанализированы результаты прогнозирования метода ARIMA[2].

Метод Хольта-Винтерса основан на трехпараметрической модели, которая используется для прогнозирования временных рядов со сложившимися трендом и сезонностью в структуре данных. Прогноз с использование данного метода высчитывается следующими формулами:

$$F_t = \alpha * \gamma_t + (1 - \alpha) * (F_{t-1} + S_{t-1}), \quad (1)$$

$$S_t = \beta * (F_t + F_{t-1}) + (1 - \beta) * S_{t-1}, \quad (2)$$

где: F_t – оценка случайных колебаний; S_t – оценка тренда; α, β – параметры модели в значениях между [0-1]; γ_t – данные; t – порядковый номер.

$$\gamma_t^* = F_{t-1} + S_{t-1}, \quad (3)$$

$$\gamma_t^* = F_n + (T - n) * S_n, \quad (4)$$

$$T = n + 1, n + 2 \dots \quad (5)$$

где: F_n – оценка случайных колебаний предыдущего показателя; S_t – оценка тренда предыдущего показателя; γ_t^* – истекший и реальный прогнозы; T – номер показателя; n – номер предыдущего показателя.

После того, как все параметры рассчитаны, необходимо найти максимально эффективные значения для α и β эмпирическим путем и рассчитать точность прогноза при помощи MAE, MSE и RMSE. Это можно сделать при помощи встроенного в Excel аналитического инструмента «Поиск решения». Параметры поиска решения устанавливаются так, чтобы минимизировать индекс MAE, изменяя ячейки, помеченные как α и β , закрытые в интервале [0-1]. После чего можно подсчитать точность прогноза. Результаты подсчета α и β , а также, фактической и среднеквадратичной ошибок прогнозов, представлены в таблице 1.

Таблица 1. – Значения ошибок и параметров α и β

α	β	MAE	MSE	RMSE	MAPE
0,80	0,05	0,1450	0,0377	0,1942	7,725%

Результаты прогнозирования представлены на рисунке 1.




Рисунок 1. – Прогнозирование методом Хольта-Винтерса

Далее было проведено 20 экспериментов по поиску параметров рекуррентной сети долгой краткосрочной памяти LSTM для достижения максимально эффективного количества нейронов, слоев и эпох, для обучения нейронной сети, результаты представлены в таблице 2.

Таблица 2. – Результаты поиска максимально эффективных параметров для модели нейронной сети LSTM

№	Кол-во эпох	Кол-во слоев	Кол-во нейронов	MAE	MSE	RMSE	MAPE
1	50	2	50	0,0089	0,0391	0,1978	7%
2	250	2	50	0,0019	0,0309	0,1758	7%
3	200	3	50	0,0005	0,0303	0,1741	6%
4	200	4	50	0,0085	0,0268	0,1638	5%
5	200	5	50	0,0028	0,0180	0,1342	5%
6	200	6	50	0,0033	0,0160	0,1266	5%
7	200	7	50	0,0045	0,0143	0,1196	5%
8	200	8	50	0,0016	0,0135	0,1160	5%
9	200	9	50	0,0016	0,0125	0,1120	5%
10	200	11	50	0,0020	0,0097	0,0986	4%
11	200	12	50	0,0007	0,0083	0,0913	4%
12	200	12	55	0,0022	0,0089	0,0950	4%
13	200	12	45	0,0024	0,0096	0,0981	4%
14	200	13	50	0,0023	0,0100	0,1001	4%
15	200	14	50	0,0020	0,0103	0,1013	4%
16	200	15	50	0,0028	0,0105	0,1026	5%
17	200	16	55	0,0033	0,0107	0,1036	5%
18	200	17	45	0,0021	0,0111	0,1053	5%
19	250	18	50	0,0036	0,0113	0,1065	5%
20	200	19	50	0,0009	0,0119	0,1090	5%

На рисунке 2 показан результат прогнозирования потребления природного газа моделью LSTM, состоящей из 12 слоев, по 50 нейронов, обученной на 200 эпохах, с единичным смещением. При анализе таблицы 2 и рисунка 2 видно, что прогностическая кривая отображает динамику потребления природного газа и повторяет все его изменения, что свидетельствует о правдоподобии прогноза при помощи данной модели.




Рисунок 2. – Результаты прогнозирования потребления природного газа на основе нейронной сети LSTM

Сравнительный анализ моделей для прогнозирования потребления природного газа сети LSTM, ARIMA и метода Хольта-Винтерса. Для сравнения результатов прогнозирования потребления природного газа модели ARIMA в основном использовался информационный критерий Акаике (AIC) – критерий, применяющийся исключительно для выбора из нескольких статических моделей. Данный критерий решает задачу оценки качества предсказаний модели на тестовой выборке при известном качестве обучения прогнозирования на обучающей выборке при условии, что модель настроена по методу максимального правдоподобия, т.е. решает задачу оценки переобучения модели. Но использовать данный показатель для оценки качества прогноза модели рекуррентной сети долгой краткосрочной памяти LSTM нельзя, поскольку все нейронные сети динамические. Поэтому, необходимо рассчитать Среднюю абсолютную процентную ошибку MAPE.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i^* - y_i}{y_i} \right|, \quad (6)$$

где: n – количество прогнозируемых данных; y_i^* – спрогнозированные значения; y_i – актуальные данные; i – порядковый номер.

Сопоставление результатов точности прогнозирования потребления природного газа методом Хольта-Винтерса (таблица 1), на основе нейронной сети LSTM (таблица 2) и моделью ARIMA[3] показывает, что показатели средней абсолютной процентной ошибки (MAPE) нейронной сети являются наименьшими, и точность ее прогноза составляет 96% (100% - MAPE).

Таблица 3. – Результаты вычисления точности прогнозирования потребления природного газа моделями метода Холта-Винтерса, нейронной сети LSTM и ARIMA

Модель	RMSE	MAPE
Метод Холта-Винтерса	0,1942	7,725%
Нейронная сеть LSTM	0,0913	4%
ARIMA	0,1187	5,2%

Заключение. При анализе результатов экспериментов по достижению максимально эффективных параметров сети LSTM [1] видно, что прогностическая кривая отображает динамику потребления природного газа и повторяет все его изменения, а точность прогноза составляет 96%, что выше точности прогнозирования модели метода Хольта-Винтерса и модели ARIMA.

ЛИТЕРАТУРА

1. Васильева, Д.М. (2022), Прогнозирование потребления природного газа клиентами ОАО «Газпром Трансгаз Беларусь» на основе искусственных нейронных сетей. – Полоцк: ПГУ. – 44 с.
2. Глухов, Д.О., Глухова, Т.М., Андриевский, А.П., Янушенок, А.П., Богуш, Р.П. & Ищенко, Л.В. (2020), Отчет о научно-исследовательской работе /Разработка методов анализа больших данных для решения задач прогнозирования потребления газа на магистральном газопроводе ОАО «Газпром Трансгаз Беларусь». – Полоцк: ПГУ. – 89 с.
3. Видмант, О.С. (2018), Прогнозирование финансовых временных рядов с использованием рекуррентных нейронных сетей LSTM. – Москва: ФУ при правительстве РФ. – 5 с.
4. Гафаров Ф.М., Галимянов А.Ф. (2018), Искусственные нейронные сети и их приложения : учеб. пособие. – Казань : Издательство Казанского университета. – 121 с.
5. Редько, В.Г. (2015), Эволюция, нейронные сети, интеллект: Модели и концепции эволюционной кибернетики / В.Г. Редько. – М.: Ленанд. – 224 с.