УДК 004.8

# СОЗДАНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ЦЕН НА ПРИРОДНЫЙ ГАЗ

# CREATING A NEURAL NETWORK MODEL FOR NATURAL GAS PRICE FORECASTING

**Семенова Дарья Вячеславовна**
инженер,
ООО «РТСИМ»,
Казанский национальный исследовательский технологический университет

**Бронская Вероника Владимировна**
доцент кафедры ПАХТ,
Казанский национальный исследовательский технологический университет
dweronika@mail.ru

**Исмагилов Ильфат Фанилевич**
студент,
Казанский национальный исследовательский технологический университет
ilfat442@gmail.com

**Semenova Darya Vyacheslavova**
Engineer of «RTSIM»,
Kazan National Research Technological University

**Bronskaya Veronika Vladimirovna**
Associate Professor,
Kazan National Research Technological University
dweronika@mail.ru

**Ismagilov Ilfat Fanilevich**
Student,
Kazan National Research Technological University
ilfat442@gmail.com

**Аннотация.** В статье исследуются возможности применения методов машинного обучения и нейросетевых архитектур для прогнозирования ценовой динамики природного газа. Актуальность работы продиктована высокой степенью волатильности энергетических рынков и объективной потребностью в повышении точности экономических предиктивных оценок.
Рассматриваются теоретические основы анализа временных рядов, обзор нейросетевых архитектур, задействуемых для прогнозирования финансовых и энергетических индикаторов, а также поэтапная методология конструирования и обучения модели. Представлен алгоритм построения нейросети на основе ретроспективных данных, детализированы ключевые этапы обработки информации, формирования обучающей выборки и верификации прогностической точности.
В работе обосновано, что применение рекуррентных нейронных сетей типа LSTM позволяет эффективно моделировать нелинейные зависимости и темпоральные закономерности, присущие ценовой динамике. Полученные результаты подтверждают перспективность интеграции методов искусственного интеллекта в аналитический контур энергетических рынков и демонстрируют потенциал повышения качества прогнозной аналитики.

**Ключевые слова:** нейронные сети, машинное обучение, прогнозирование, природный газ, временные ряды, энергетический рынок, LSTM, анализ данных.

**Annotation.** The article examines the application of machine learning and neural network methods for forecasting natural gas prices. The study discusses theoretical foundations of time series analysis and the use of recurrent neural networks such as LSTM. The stages of building and training the model, including data preprocessing, dataset formation, and evaluation of forecasting accuracy, are described. The results demonstrate that neural network models are capable of capturing nonlinear dependencies in energy market data and can improve the accuracy of economic forecasts.

**Keywords:** neural networks, machine learning, forecasting, natural gas, time series, energy market, LSTM.

## Введение

Прогнозирование цен на энергетические ресурсы является одной из ключевых задач современной экономики. Природный газ занимает важное место в мировой энергетической системе и используется для выработки электроэнергии, отопления жилых и промышленных объектов, а также в химической промышленности. Колебания стоимости рассматриваемого энергоресурса служат значимым фактором, воздействующим на экономику государств, долгосрочные инвестиционные планы компаний и вектор энергополитики.

Нынешняя конъюнктура энергетических рынков отличается крайней нестабильностью и сложным переплетением детерминант, влияющих на итоговую цену.

Традиционный инструментарий прогнозирования, базирующийся на статистических и эконометрических моделях, не всегда адекватно отражает нелинейные зависимости между переменными.

Искусственные нейронные сети, напротив, демонстрируют способность обнаруживать латентные закономерности в данных, обрабатывать крупные информационные массивы и обеспечивать более высокую точность оценок. В этой связи использование нейросетевых моделей для прогнозирования временных рядов цен на природный газ является научно и практически востребованным направлением [1–7].

**Теоретические основы применения нейронных сетей**

Информация о стоимости природного газа представлена в виде временных рядов – хронологически упорядоченных наборов данных, которым присущи долговременные тренды, периодические колебания и случайные отклонения. Рекуррентные нейросети считаются одним из наиболее результативных решений в этой области. Они улавливают зависимость между текущим значением и его временными предшественниками. Особенно выделяются LSTM-архитектуры (Long Short-Term Memory), сохраняющие информацию о долгосрочных зависимостях внутри временной последовательности.

Главное преимущество нейросетей – их способность воспроизводить нелинейные функциональные зависимости любой сложности. Это делает их крайне востребованными при анализе экономических явлений, где влияние разнородных факторов часто имеет нелинейную природу и сложно структурировано.

**Методика построения модели**

Для решения задачи прогнозирования цен на природный газ в рамках данной работы была разработана и реализована архитектура глубокого обучения – рекуррентная нейросеть с механизмом долгой краткосрочной памяти (LSTM). Исходные выборки загружались напрямую с официального портала Управления энергетической информации США (EIA) с применением инструментария pandas. Последующая подготовка данных включала: удаление пропущенных записей, нормализацию временных меток, сортировку индексов и заполнение оставшихся лакун средним арифметическим значением. Для повышения устойчивости обучения и ускорения сходимости градиентных методов данные были нормализованы в диапазон [0, 1] с помощью MinMaxScaler из библиотеки scikit-learn. Подготовка временных рядов для обучения LSTM осуществлялась посредством TimeseriesGenerator, который формировал скользящие окна фиксированной длины (10 предыдущих наблюдений) для прогноза следующего значения. Архитектура сети включала один слой LSTM с 10 нейронами и функцией активации ReLU, за которым следовал полносвязный слой с одним выходным нейроном для задачи регрессии; компиляция модели производилась с оптимизатором Adam и функцией потерь MSE. Для предотвращения переобучения применялась ранняя остановка (EarlyStopping) с терпением в 5 эпох, что позволило завершить обучение при отсутствии улучшений на валидационной выборке.

После обучения модель была сохранена в формате .keras для последующего использования без необходимости повторного обучения. Прогнозирование выполнялось на тестовой выборке, не участвовавшей в тренировке, с последующим обратным масштабированием предсказанных значений в исходные единицы измерения (доллары за миллион британских термических единиц).

Визуализация результатов осуществлялась с помощью библиотеки matplotlib: на одном графике отображались фактические данные обучающей и тестовой выборок, а также полученный прогноз, что позволило наглядно оценить качество работы модели. Нормализация, временные срезы и LSTM – образуют методологию, эффективную для рядов с сильной автокорреляцией. При этом инструментарий универсален: он масштабируется на иные экономические и энергетические метрики

**Результаты моделирования**

По окончании тренировочного процесса модели проводится верификация полученных результатов. Сопоставление фактических данных с модельными прогнозами служит ценкой точности функционирования нейросетевой архитектуры.

**Рисунок 1** – Сравнение реальных и прогнозируемых значений цен на природный газ

Визуальная оценка графического материала подтверждает, что модель корректно воспроизводит ценовую траекторию: сохраняется генеральный тренд и адекватно передаются ключевые осцилляции временного ряда (рис. 1). Отдельные локальные расхождения не нарушают общей картины – прогнозная линия в целом изоморфна эмпирическим данным.

Монотонное убывание функции потерь в ходе увеличения количества эпох указывает на корректность процесса обучения модели и последовательную редукцию прогностической ошибки. Данный факт верифицирует эффективность выбранной нейросетевой архитектуры.

**Практическое значение**

Полученные результаты обладают прикладной ценностью для широкого круга стейкхолдеров: энергетических компаний, финансовых аналитиков и участников трейдинговых операций (рис. 2). Прогностические оценки стоимости природного газа создают основу для более точной калибровки рыночных рисков, формирования инвестиционных стратегий и принятия экономически обоснованных управленческих решений.

**Рисунок 2** – Динамика изменения цены в процессе обучения модели и прогноз на 2027–2028 года

Предложенный модельный аппарат не ограничивается природным газом – он применим для анализа иных энергетических активов, включая нефть, уголь и электроэнергию. Внедрение методов искусственного интеллекта в энергетическую сферу формирует новый технологический уклад, открывающий дополнительные каналы повышения операционной эффективности управления ресурсами

**Заключение**

В статье изложен процесс конструирования нейросетевой модели, ориентированной на прогнозирование цен природного газа. Эмпирически показано, что задействование рекуррентных архитектур позволяет релевантно моделировать сложные нелинейные зависимости во временных рядах и достигать более высокой точности прогнозов.

Вектор дальнейших исследований может быть развернут в трёх направлениях: апробация более сложных нейросетевых конфигураций, интеграция в модель дополнительных предикторов (метеорологические условия, динамика добычи, глобальные экономические индикаторы) и разработка гибридных прогностических алгоритмов. Реализация этих направлений позволит повысить аналитическую мощность систем поддержки решений и расширить горизонты внедрения искусственного интеллекта в энергетическую экономику.

**Список литературы:**

1. Goodfellow I., Bengio Y., Courville A. Deep Learning. – Cambridge : MIT Press, 2016.
2. Chollet F. Deep Learning with Python. – New York : Manning Publications, 2018.
3. Bishop C. Pattern Recognition and Machine Learning. – Springer, 2006.

4. Zhang G., Patuwo B., Hu M. Forecasting with artificial neural networks // International Journal of Forecasting. – 1998.
5. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. – 1997.
6. Цапаев А.А., Харитонова О.С., Бронская В.В. Нейросетевая модель процесса утилизации промышленных водных стоков // Приоритетные направления развития науки и технологий : доклады XXVI международной научно-практической конференции, Тула, 15 декабря 2019 года / Под общей редакцией В.М. Панарина. – Тула : Издательство «Инновационные технологии», 2019. – С. 150–152.
7. Мухаметзянова А.Г., Бронская В.В., Харитонова О.С. Нейросетевое моделирование гидродинамики потока в колонных аппаратах с насадочными элементами // Вестник Технологического университета. – 2021. – Т. 24. – № 12. – С. 139–141.

**List of references:**

1. Goodfellow I., Bengio Y., Courville A. Deep Learning. – Cambridge : MIT Press, 2016.
2. Chollet F. Deep Learning with Python. – New York : Manning Publications, 2018.
3. Bishop C. Pattern Recognition and Machine Learning. – Springer, 2006.
4. Zhang G., Patuwo B., Hu M. Forecasting with artificial neural networks // International Journal of Forecasting. – 1998.
5. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. – 1997.
6. Tsapaev A.A., Kharitonova O.S., Bronskaya V.V. Neural network model of the industrial wastewater disposal process // Priority areas of science and technology development: reports of the XXVI international scientific and practical conference, Tula, December 15, 2019 / General editor V.M. Panarin. – Tula : Innovative Technologies Publishing House, 2019. – P. 150–152.
7. Mukhametzyanova A.G., Bronskaya V.V., Kharitonova O.S. Neural network modeling of flow hydrodynamics in column apparatuses with packed elements // Bulletin of the Technological University. – 2021. – Vol. 24. – № 12. – P. 139–141.