

УДК 004.7:628.14

А.А. Капанский

*Гомельский государственный технический университет им. П.О. Сухого,
Гомель, Беларусь, 246029
e-mail: kapanski@mail.ru*

МОДЕЛИРОВАНИЕ ДАВЛЕНИЯ В СИСТЕМАХ ВОДОСНАБЖЕНИЯ С ПРИМЕНЕНИЕМ LSTM-РЕКУРРЕНТНЫХ НЕЙРОСЕТЕЙ

В статье представлен метод прогнозирования гидравлического давления в системах водоснабжения с использованием рекуррентных нейронных сетей, в частности модели с долгой краткосрочной памятью (LSTM). Основываясь на данных, получаемых с пьезоэлектрических датчиков давления, интегрированных в сеть через протокол MQTT, исследование демонстрирует значительное превосходство LSTM-модели над традиционными моделями. Это подчеркивает не только высокую точность прогноза, но и возможность более эффективного управления системами водоснабжения. Преимущество данной архитектуры заключается в ее гибкости и способности адаптироваться к изменяющимся условиям эксплуатации, благодаря обработке новых данных, поступающих на сервер в реальном времени. Базовые принципы построения и настройки модели LSTM могут быть легко модифицированы для прогнозирования различных параметров, что расширяет перспективы использования рекуррентных нейросетей в управлении инженерными системами.

Ключевые слова: гидравлическое давление, рекуррентные нейронные сети, модель долгой краткосрочной памяти, системы ресурсоснабжения, датчики давления.

A.A. Kapansky

*Sukhoi State Technical University of Gomel,
Gomel, Belarus, 246029
e-mail: kapanski@mail.ru*

PRESSURE MODELING IN WATER SUPPLY SYSTEMS USING LSTM RECURRENT NEURAL NETWORKS

The method for forecasting hydraulic pressure in water supply systems using recurrent neural networks, specifically the long short-term memory (LSTM) model is presented. Based on data obtained from piezoelectric pressure sensors integrated into the network via the MQTT protocol, the study demonstrates a significant superiority of the LSTM model over traditional models. This fact highlights not only the high accuracy of the forecast but also the potential for more efficient water supply system management. The advantage of this architecture lies in its flexibility and ability to adapt to changing operational conditions through real-time processing of new data sent to the server. The basic principles of constructing and configuring the LSTM model can be easily modified to forecast various system parameters, expanding the prospects for using recurrent neural networks in managing engineering systems.

Key words: hydraulic pressure, recurrent neural networks, long short-term memory model, resource supply systems, pressure sensors.

Эффективность и надежность систем ресурсоснабжения играют ключевую роль в бесперебойной работе городской инфраструктуры [1, 2]. Внедрение передовых технологий для анализа и прогнозирования динамики таких систем становится важной задачей, способной не только помочь в оперативном выявлении и устранении аварийных ситуаций, но и предложить пути для оптимизации их работы [3–5]. Одним из наиболее мощных инструментов в этом направлении являются рекуррентные нейронные сети (РНС), особенно модели с долгой краткосрочной памятью (LSTM), которые способны учитывать влияние прошлых данных на будущие изменения. В текущем исследовании рассматривается применение LSTM модели для прогнозирования гидравлического давления в системах водоснабжения. Разработка таких моделей позволяет учиты-

вать множество переменных факторов, что способствует более глубокому пониманию работы сложных технических систем и разработке стратегий для их оптимизации, повышения надежности и эффективности.

Несмотря на то, что основное внимание в работе отводится системам водоснабжения, стоит отметить, что алгоритмы искусственного интеллекта также активно используются или могут адаптироваться к другим областям, таким как газоснабжение, нефтяная промышленность или теплоснабжение. Фундаментом для успешной интеграции прогностических моделей служит развитие и поддержание высококачественной информационной инфраструктуры, способной обрабатывать большие объемы данных в реальном времени. Интеграция современных технологий Интернета вещей (IoT) и облачных вычислений играет здесь первостепенную роль, поскольку обеспечивает бесперебойный поток данных от датчиков к аналитическим центрам и обратно к системам управления.

В рамках исследования была создана информационная платформа на базе Гомельской системы водоснабжения Беларуси, ключевым аспектом которой стало оперативное получение гидравлических параметров. Для достижения высокой точности измерений использовались пьезоэлектрические преобразователи давления вместе с модемами RTU-8xx российской компании АО «Телеофис». Сбор и передача информации осуществлялись по протоколу MQTT, который, выполняя функции брокера, эффективно координировал взаимодействие между устройствами [6–8]. На рис. 1 демонстрируется процесс подключения датчика давления и модема в условиях эксплуатации повысительной насосной станции (ПНС).



Рис. 1. Процесс подключения первичного преобразователя давления к устройству сбора и передачи данных ПНС

Датчики давления, установленные на ключевых узлах системы водоснабжения, подключались к устройствам сбора и передачи данных, которые выполняли функцию «Издателя». Эти устройства регулярно отправляли данные на вычислительный сервер, где брокер MQTT играл центральную роль в процессе: он принимал данные от издателей и распределял их между подписчиками, такими как персональные компьютеры и мобильные устройства пользователей. Это обеспечивало централизованное и надежное распределение информации, позволяя подписчикам обрабатывать данные в зависимости от их задач. Такая архитектура не только упростила процесс мониторинга системы, но и обеспечила оперативный доступ к данным о гидравлическом давлении, которые впоследствии использовались для обучения моделей искусственного интеллекта. На рис. 2 демонстрируется принятая архитектура модели нейронной сети. Эта структура модели была определена как оптимальная для данной задачи после серии экспериментов и тестирований, позволяя максимально точно прогнозировать динамику гидравлического давления и другие связанные параметры.

Определяющими параметрами базовой архитектуры сети являлись: 50 нейронов в каждом из слоев LSTM и полносвязном слое, подача 12 исторических наблюдений на вход модели и 12 значений прогнозирования, и использование одного параметра входа – измеренного давления с интервалом в 5 минут.

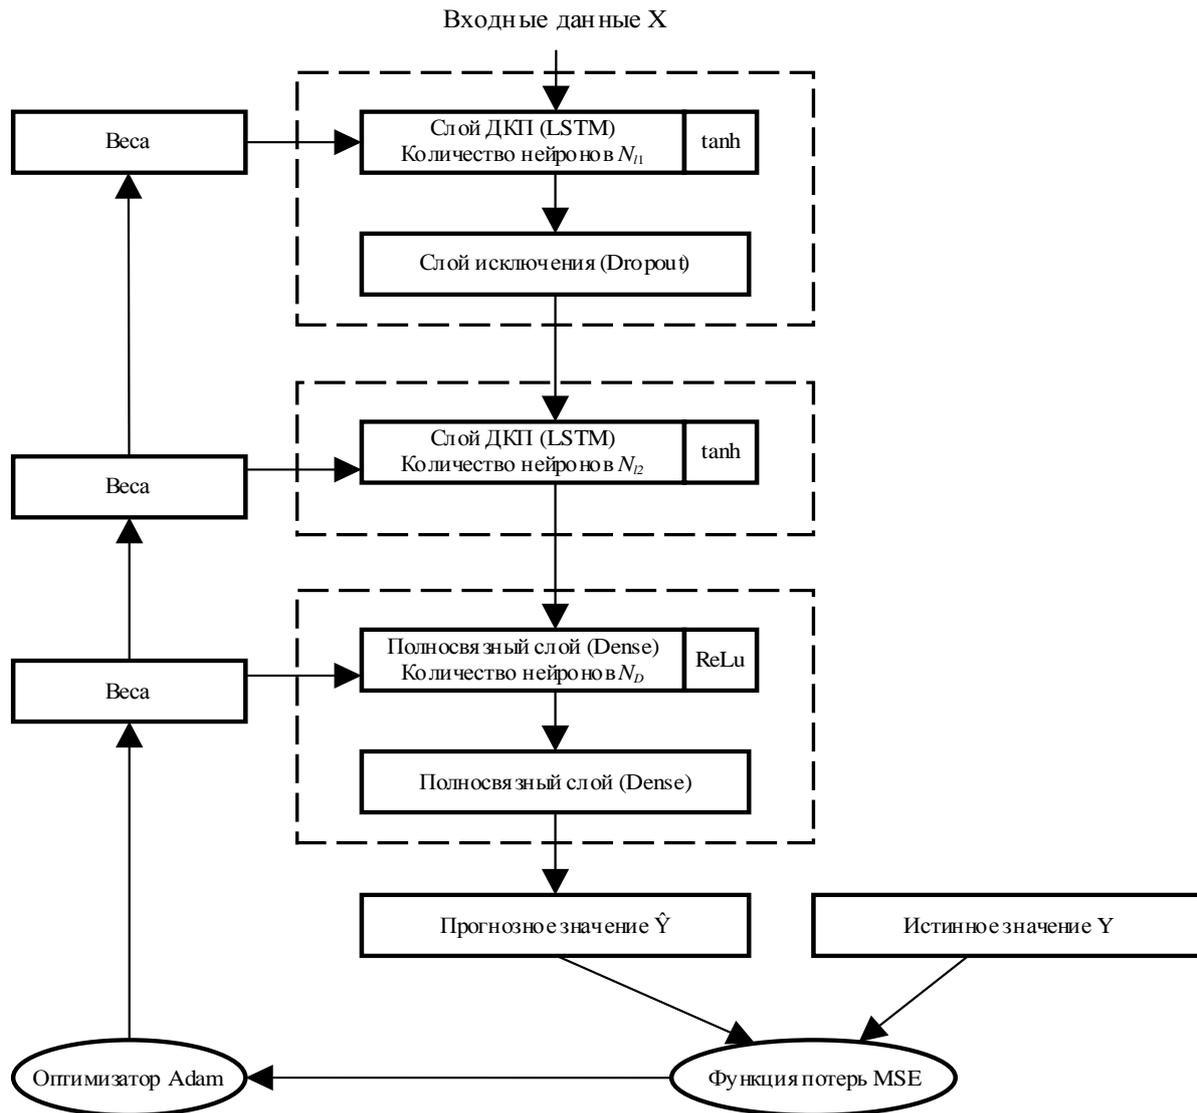


Рис. 2. Принятая архитектура модели нейронной сети для прогнозирования давления

Архитектура нейросетевой модели, используемая для обработки и анализа собранных данных, включала в себя следующие ключевые элементы:

1. *Слой LSTM (Долгая краткосрочная память)*: два слоя LSTM составили основу обработки временных последовательностей, таких как показания давления, благодаря их способности сохранять информацию о предыдущих состояниях системы, что является критически важным для задач прогнозирования.

2. *Функции активации*: гиперболический тангенс (tanh) был применен в слоях LSTM для нормализации значений в диапазоне от -1 до 1 , что способствовало модуляции информации между слоями. Функция активации ReLU (Rectified Linear Unit) применялась в полносвязных слоях (Dense), внося нелинейность в модель и позволяя выявлять более сложные зависимости в данных.

3. *Полносвязные слои (Dense)*: слои с большим количеством параметров служили для агрегации и взвешивания признаков, извлеченных из данных LSTM слоев, преобразовывая их в предсказания.

4. *Оптимизатор Adam и функция потерь MSE*: это сочетание гарантировало эффективность и стабильность в процессе обучения модели, способствуя минимизации ошибок и постепенному улучшению точности прогнозов.

В рамках проведенного исследования были изучены семь разнообразных конфигураций нейросетевых моделей, отличающихся количеством и комбинациями слоев LSTM, Dropout и Dense. Основной целью было определение структуры модели, которая обеспечивает наиболь-

шую точность прогнозирования. Анализ результатов показал, что модели с увеличенным до двух или трех количеством слоев LSTM демонстрировали значительное улучшение в прогнозировании. Это подтверждалось снижением показателей таких метрик, как MAPE, SMAPE, MAE и RMSE, в сравнении с однослойной архитектурой LSTM. Добавление слоя регуляризации Dropout способствовало дополнительному улучшению производительности моделей. Особенно хорошие результаты показали модели с одним или двумя слоями Dropout. Модели с одним слоем Dense превосходили в эффективности модели с двумя полносвязными слоями.

Отмечалось, что с увеличением числа слоев и параметров росло и время, необходимое для обучения моделей. В частности, модель с тремя слоями LSTM, а также с Dropout и Dense, требовала вдвое больше времени по сравнению с моделью, состоящей из двух слоев LSTM и одного слоя каждого Dropout и Dense при схожей точности прогнозов. В результате оптимальной структурой модели для прогнозирования гидравлического давления оказалась та, что включала два слоя LSTM, один слой Dropout и один полносвязный слой Dense (рис. 2). Эта конфигурация демонстрировала погрешность на тестовой выборке с MAPE равной 4,79% на 20 эпохах обучения, что свидетельствует о ее высокой эффективности и адекватности для решения поставленной задачи. На рис. 3 демонстрируется влияние архитектуры нейронной сети на результаты моделирования.

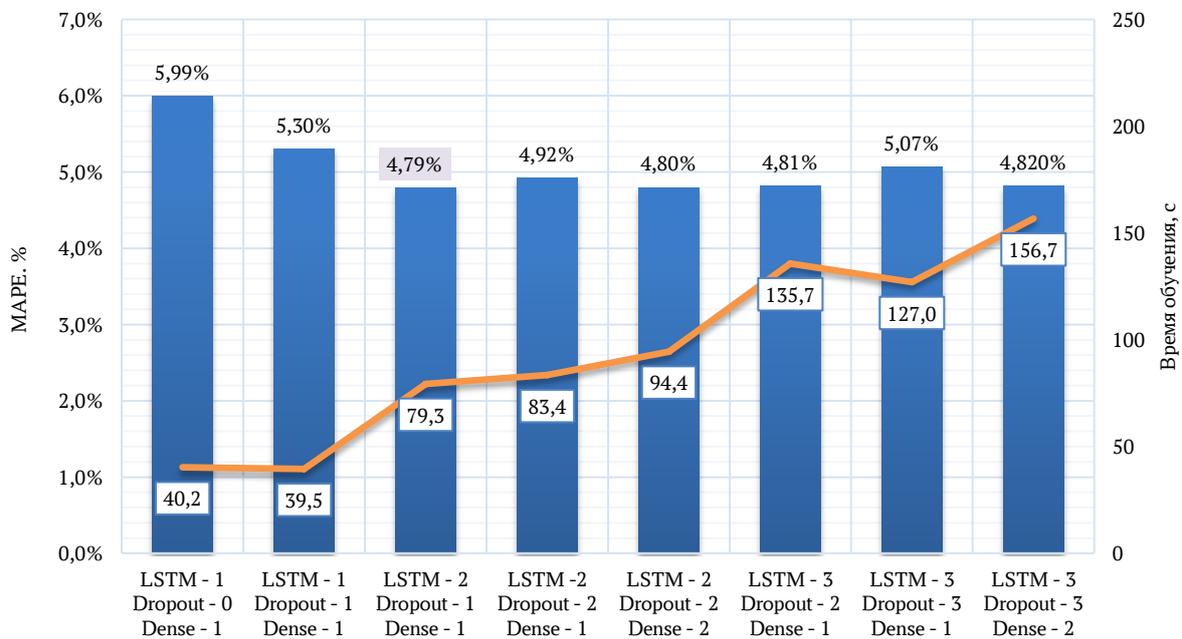


Рис. 3. Влияние архитектуры нейронной сети на производительность модели

В процессе исследования особое внимание было уделено анализу глубины прогноза, т. е. количества шагов (интервалов), на которые модель может предсказать будущие значения. Результаты показали, что точность прогнозирования зависит от глубины горизонта: чем дальше модель пытается предсказать, тем больше возможная ошибка. Минимальная ошибка MAPE, зафиксированная на уровне 4,09%, наблюдалась при прогнозировании на два шага вперед. С увеличением шагов прогнозирования ошибка постепенно возрастала, достигая 5,55% на глубине в 12 шагов.

Зависимость рис. 4 отражает сложности, возникающие при попытке модели адекватно оценить воздействие факторов, которые могут стать более непредсказуемыми на более длительных временных интервалах. К таким факторам относятся, например, сезонные колебания, дневные и недельные циклы, которые характерны для гидравлических систем и могут существенно повлиять на точность прогнозов.

С учетом полученных данных можно сделать вывод, что для обеспечения наилучшей точности предсказаний важно найти оптимальный баланс между желаемой глубиной прогноза и допустимой погрешностью. Выбор шага прогноза должен соответствовать специфическим целям и ограничениям конкретной задачи, учитывая не только потребность в точности, но и необходимость предвидения будущего на приемлемое расстояние во времени.

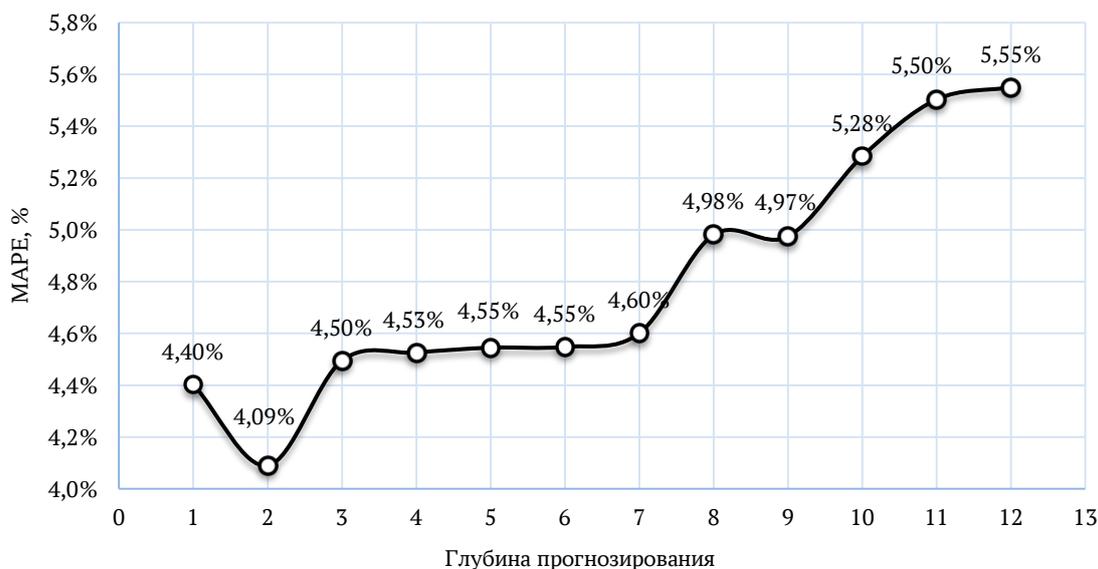


Рис. 4. Влияние архитектуры нейронной сети на производительность модели

В процессе осуществления проекта, направленного на оптимизацию и увеличение эффективности функционирования систем ресурсоснабжения, была оказана неоценимая поддержка со стороны руководства и специалистов Государственного предприятия «Гомельводоканал». Этот вклад оказался неоценимым не только в уточнении и повышении точности моделей прогнозирования, но и в целом способствовал прогрессу в интеграции и адаптации передовых технологических решений в практическую деятельность предприятия.

Литература

1. Белов О.А. Методология оценки технического состояния электрооборудования при развитии параметрических отказов // Вестник Астраханского государственного технического университета. Серия: Морская техника и технология. – 2015. – № 3. – С. 96–102.
2. Белов О.А., Парфенкин А.И. Системная интеграция контроля электрооборудования // Электротехнические и информационные комплексы и системы. – 2014. – Т. 10. – №. 1. – С. 14–17.
3. Optimization of a variable frequency drive pump working on a water tower / N.V. Hruntovich, A.A. Kapanski, D. Baczynski, G.V. Vagapov, O.V. Fedorov // E3S Web of Conferences. – EDP Sciences, 2019. – Vol. 124. – P. 05060. ()
4. Оптимизация схем электроснабжения промышленных предприятий / Е.И. Грачева, Т.В. Синюкова, Т.В. Табачникова, А.Н. Алимova. – Казань: Казанский государственный энергетический университет, 2022. – 135 с. – EDN SMARQD.
5. Ezechi C.G., Okoroafor E.R. Integration of Artificial Intelligence with Economical Analysis on the Development of Natural Gas in Nigeria; Focusing on Mitigating Gas Pipeline Leakages // SPE Nigeria Annual International Conference and Exhibition. – SPE, 2023. – С. D031S018R004.
6. Zyrianoff I. et al. Scalability of an Internet of things platform for smart water management for agriculture // 2018 23rd conference of open innovations association (FRUCT). – IEEE, 2018. – С. 432–439.
7. Thangavel D. et al. Performance evaluation of MQTT and CoAP via a common middleware // 2014 IEEE ninth international conference on intelligent sensors, sensor networks and information processing (ISSNIP). – IEEE, 2014. – С. 1–6.
8. Использование интеллектуальных систем учета электрической энергии в целях повышения эффективности процесса тарифообразования / Т.А. Мусаев, О.В. Федоров, Р.Н. Камалиев, А.А. Капанский // Вестник Гомельского государственного технического университета им. П.О. Сухого. – 2020. – № 2. – С. 68–75.