

УДК 004.8

DOI: [10.26102/2310-6018/2022.38.3.001](https://doi.org/10.26102/2310-6018/2022.38.3.001)

## Моделирование системы искусственного интеллекта для опережающего выявления аварийных ситуаций на жизненно важных объектах

И.Г. Боровской, Е.А. Шельмина✉, И.Г. Афанасьева, А.А. Матолыгин

*Томский государственный университет систем управления и радиоэлектроники,  
Томск, Российская Федерация  
eashelmina@mail.ru✉*

**Резюме.** В статье приводятся результаты моделирования системы искусственного интеллекта для опережающего выявления нежелательных ситуаций различного характера на объектах, представляющих важнейшее народнохозяйственное значение. В качестве такого объекта можно указать трубопроводный транспорт или любую другую производственную систему, в которой проводится непрерывный мониторинг параметров работоспособности ответственных узлов и механизмов. Данная модель может быть применена в работе различных нефтегазодобывающих компаний. Результаты моделирования и последующей разработки информационной системы предоставят базу для промышленной реализации высокоэффективных систем обнаружения и предотвращения аварийных ситуаций на основе нейросетевого анализа непрерывно получаемых потоковых данных. В рамках проводимого исследования проанализирована возможность применения для рассматриваемой задачи современных архитектур нейросетей, а именно: сверточных нейросетей – TCN, нейронных сетей прямого распространения – MLP, рекуррентных нейронных сетей – LSTM. Предложено для LSTM отказаться от функции активации, что крайне важно для данной задачи, потому что позволяет обеспечить нейросеть «долговременной памятью» о хранимых значениях. Кроме того, выполнено перекрестное сравнение скорости снижения ошибок при обучении сетей для обнаружения архитектуры, способной к «самообучению». Все модели были протестированы с использованием обучающих данных со скважин «Восточный купол». Для всех моделей было получено приемлемое совпадение тестовых и экстраполяционных данных.

**Ключевые слова:** искусственный интеллект, временной ряд, искусственная нейронная сеть, чрезвычайная ситуация, архитектура нейросетей, сверточные нейросети, нейронные сети прямого распространения, рекуррентные нейронные сети.

**Для цитирования:** Боровской И.Г., Шельмина Е.А., Афанасьева И.Г., Матолыгин А.А. Моделирование системы искусственного интеллекта для опережающего выявления аварийных ситуаций на жизненно важных объектах. *Моделирование, оптимизация и информационные технологии.* 2022;10(3). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1197> DOI: 10.26102/2310-6018/2022.38.3.001

## Modeling of artificial intelligence system for early detection of emergency situations at vital facilities

I.G. Borovskoy, E.A. Shelmina✉, I.G. Afanasyeva, A.A. Matolygin

*Tomsk State University of Control Systems and Radioelectronics, Tomsk, Russian Federation  
eashelmina@mail.ru✉*

**Abstract.** The article presents the results of modeling an artificial intelligence system for early detection of undesirable situations of various types at objects of particular national economic importance. Pipeline transport or any other production system, in which continuous monitoring of operability parameters of

critical components and mechanisms is carried out, can be specified as such object. This model can be applied by various oil and gas production companies. The results of modeling and subsequent development of the information system will provide the basis for industrial implementation of highly effective systems of accident detection and prevention in reliance on neural network analysis of continuously received streaming data. As a part of this research, the possibility of using modern neural network architectures for the problem under consideration is examined, namely, convolutional neural networks – TCN, direct propagation neural networks – MLP, recurrent neural networks – LSTM. It was proposed to abandon the activation function for LSTM which helps to provide the neural network with "long-term memory" of stored values, which is crucial to this problem. In addition, a cross-comparison of the error reduction rate during network training was performed to detect an architecture capable of "self-learning". All models were tested with the aid of the training data from the "Vostochny kupol" wells. Acceptable coincidence of test and extrapolation data was obtained for all models.

**Keywords:** artificial intelligence, time series, artificial neural network, emergency, neural network architecture, convolutional neural networks, direct propagation neural networks, recurrent neural networks.

**For citation:** Borovskoy I.G., Shelmina E.A., Afanasyeva I.G., Matolygin A.A. Modeling of artificial intelligence system for early detection of emergency situations on vital objects. *Modeling, Optimization and Information Technologies*. 2022;10(3). Available from: <https://moitvvt.ru/ru/journal/pdf?id=1197> DOI: 10.26102/2310-6018/2022.38.3.001 (In Russ.).

## Введение

Система газоснабжения России отличается географической удаленностью между основными газодобывающими и газопотребляющими регионами. Это, соответственно, требует создания крупнейшей газотранспортной системы для обеспечения доставки газа потребителям. При эксплуатации газопроводов случаются разные аварии и чрезвычайные ситуации, связанные с разными факторами: природные условия, человеческий фактор, вмешательство извне и другие. Часто такие аварии или чрезвычайные ситуации приводят к активизации опасных явлений [1]. Поэтому для предотвращения аварий или хотя бы уменьшения их последствий необходимо проводить комплексный и систематический мониторинг состояния трубопроводов. Один из вариантов решения этой проблемы – это использование нейронных сетей, которые позволят минимизировать затраты и повысить точность оценки состояния газопроводов и, как следствие, предотвратить возможные ЧС.

В настоящее время нейронные сети приобретают все большую популярность и им посвящено большое количество исследований современных авторов. Так, авторы [2-5] отмечают, что «различные системы управления на основе нейронных сетей можно рассматривать как альтернативу классическим системам». Также стоит отметить, что известен ряд возможных архитектур для построения систем управления нейронными сетями, а также систем управления, в которых нейрорегуляторы работают параллельно с обычными контроллерами [2-5]. В основном интеллектуальные нейронные сети (ИНС) используются для распознавания образов, но в последнее время область их применения значительно расширилась и нейронные сети стали использовать в нефтегазовой отрасли. Так, многие нефтегазодобывающие компании запускают различные проекты, в основе которых лежит принцип «умного» месторождения [3].

На сегодняшний день развиты несколько направлений применения ИНС в нефтегазовой отрасли – разведка, бурение и предотвращение аварийных ситуаций. Для каждого из этих направлений цель использования искусственных нейронных систем – более продуктивное использование скважин, сокращение расходов на эксплуатацию и увеличение объемов добываемой нефти.

Направление, связанное с предотвращением различных аварийных и чрезвычайных ситуаций, является актуальным и развивающимся, позволяет минимизировать человеческий фактор, так как искусственный интеллект в автоматическом режиме при получении тех или иных данных будет идентифицировать дефект или попытку вмешательства и соотносить его с уже имеющейся базой. Датчики и технологии разработанной системы искусственного интеллекта смогут распознать аварийные ситуации и передать сигнал о них операторам или административным центрам, что позволит нефтегазовым компаниям улучшить производительность и добычу, а также оптимизировать расходы.

Целью данной работы является моделирование системы искусственного интеллекта для опережающего выявления аварийных ситуаций и последующая разработка соответствующей информационной системы.

Для достижения поставленной цели были решены следующие задачи: анализ архитектур нейронных сетей, проведение вычислительного эксперимента для выбранных моделей нейронных сетей, составление рекомендаций о применимости рассмотренных нейронных сетей для решения задачи выявления аварийных ситуаций.

### **Материалы и методы**

Задачей отслеживания аварийных ситуаций является проверка предельно допустимой концентрации (далее ПДК) опасного вещества в реальном времени с целью предупреждения диспетчера о возможных уровнях превышения. Например, в проекте [6] одной из основных базовых функций системы отслеживания аварийных ситуаций является непрерывное измерение концентраций таких соединений, как хлор, аммиак и оповещение о нескольких уровнях превышения ПДК: 1 ПДК, 3 ПДК, 25 ПДК. При этом есть возможность определить, является ли авария локальной, при которой есть риск выхода облака токсичных соединений за пределы места утечки, либо уже произошла аварийная ситуация. Для отслеживания аварийных ситуаций обычно применяются временные ряды из показаний целой группы датчиков.

Промышленное оборудование имеет высокие капитальные затраты, и его эффективное использование зависит от низких эксплуатационных расходов. Для соблюдения этих требований мониторинг состояния и диагностика оборудования стали общепринятыми отраслевыми инструментами [7, 12, 13].

Это делается для того, чтобы потенциальные проблемы можно было обнаружить и диагностировать на ранней стадии их развития и исправить с помощью соответствующих мер по восстановлению до того, как они станут достаточно серьезными, чтобы вызвать поломку оборудования и другие серьезные последствия.

В конечном результате все больший объем данных мониторинга состояния собирается и представляется инженерному составу предприятия. Значительный объем поступающих данных мониторинга приводит к следующим проблемам:

- 1) величина объема данных затрудняет его «ручной» разбор;
- 2) затрудняется установка связи между элементами промышленного оборудования и их состоянием, из-за чего, полученные мониторингом данные элементов оборудования не всегда могут точно сообщить о состоянии оборудования.

Поэтому извлечение значимой информации из данных мониторинга состояния является нетривиальной задачей. Кроме того, во многих случаях увеличение объема различных типов измерительных данных коррелирует с возлагаемой на инженеров нагрузкой, что также может привести к ложным выводам о состоянии оборудования.

Также в большинстве случаев измеренные данные либо частично оцениваются, либо вообще не анализируются. Ручной анализ данных в подавляющем большинстве

случаев занимает много времени и практически невозможен в случае больших наборов данных.

Алгоритмы машинного обучения [14] оказались одним из наиболее перспективных подходов к извлечению неизвестных отношений и знаний в больших наборах данных. Эти методы используются в широком спектре отраслей промышленности для получения дополнительных выгод от записанных данных [15].

Любые механизмы промышленного оборудования в конечном итоге подвергаются процессу износа, что ведет к снижению уровня потребительских свойств машины и уменьшению ее работоспособности.

Примером износа оборудования может служить износ газопроводного оборудования при эксплуатации газоконденсатных скважин [11].

Также при эксплуатации газоконденсатных скважин возможны следующие осложнения [11]: падение пластового давления быстрее запланированного, вынос песка и механических примесей выше допустимых значений, негерметичность обсадных колонн.

Многие осложнения при эксплуатации газоконденсатных скважин возникают из-за отсутствия возможности отследить во время мониторинга исходные данные скважины, наблюдая за обработанной телеметрией устьевых показателей датчиков: давлением, температурой и расходом. Временные ряды показателей датчиков используются для обнаружения и выделения признаков, по которым будет возможно распознать наступление события как предвестника аварийного состояния, что характеризуется изменением значений параметров, таких как величина, скорость и длительность изменения [13]. Поиск во временном ряду таких событий – процесс, который необходимо автоматизировать при помощи программного модуля.

Рассмотрим следующие нейронные сети, которые наиболее подходят для анализа временных рядов: temporal convolutional network (TCN) [16], multilayered perceptron (MLP) [8], long short-term memory (LSTM) [9].

Сверточные нейронные сети обычно связаны с задачами классификации изображений. Данные нейронной сети являются многослойными, с функцией активации произвольно выбранной исследователем. Сверточная сеть TCN предложена для анализа временных рядов и состоит из расширенных причинно-следственных сверточных одномерных слоев с одинаковой входной и выходной длиной [16].

MLP – это класс искусственных нейронных сетей с прямой связью. Обучение MLP использует контролируемое обучение и обратное распространение. В качестве активационных функций нейронов используются сигмоидальные: логистический или гиперболический тангенс. На основании приведенной характеристики MLP можно сделать вывод, что если данные представлены в виде изображения, документа или временного ряда, то MLP подходит для решения задачи с таким набором данных [8].

LSTM [9] – это особый вид архитектуры рекуррентной нейронной сети, способной изучать долгосрочные зависимости. Данная архитектура специально разработана, чтобы избежать проблемы долгосрочной зависимости, сохраняя значения как для коротких, так и для длительных периодов времени [9].

Для вышеупомянутых нейронных сетей с целью обнаружения аномалий во временных рядах предлагается использовать алгоритм, основанный на скользящих окнах.

Алгоритм скользящего окна делит данный временной ряд на окна – подпоследовательности фиксированного размера, чтобы локализовать причину аномалии в одном или нескольких окнах. Оценка аномалий временного ряда теста вычисляется путем агрегирования оценок аномалий его окон. Оконные методы захватывают все различные типы аномалий: одиночные аномалии во временных рядах,

аномальные подпоследовательности во временных рядах, аномальные временные ряды в целом.

Таким образом, для выбора нейронной сети необходимо учитывать спецификацию информационной системы. Так, TCN подходит для обработки больших объемов данных, LSTM для кратковременных изменений на временном ряду, MLP подходит для обработки сильно отклоняющихся данных.

## Результаты

Для исследования описанных выше моделей нейронных сетей использовались обучающие данные, источником которых является фонд скважин «Восточный купол» – 33 скважины за период с 11.12.14 по 29.01.17.

Рассматриваемые данные представлены следующими величинами:

- давление до устройства регулирования (кгс/см<sup>2</sup>);
- давление после устройства регулирования (кгс/см<sup>2</sup>);
- температура в точке приема до устройства регулирования (°C);
- расход в точке приема до устройства регулирования (м<sup>3</sup>/сут).

Устройством регулирования (УР) является трубопроводная арматура, предназначенная для регулирования расхода и давления сырого природного газа, газоконденсатных и газонефтяных смесей. УР устанавливаются на трубопроводах кустов скважин, на линиях входа в ЗПА, на линиях УКПГ [10].

Исходные данные представлены в следующем виде: РТ2011-202 (давление до УР), РТ2011-204 (давление после УР), ТТ2011-101 (температура в ТП до УР), FT2011-301-1 (расход в ТП до УР).

С целью обнаружения гидратообразования были проанализированы газоконденсатные скважины за период с 11.12.14 по 29.01.17. Анализ скважин проводился в рамках их основных показателей (давление до УР (кгс/см<sup>2</sup>), давление после УР (кгс/см<sup>2</sup>), температура в ТП до УР (°C), расход в ТП до УР (м<sup>3</sup>/сут)).

Реализация задачи распознавания предаварийных ситуаций (РПАС) включает в себя следующие этапы:

1. Анализ объекта исследования и поиск необходимых признаков как результата измерений параметров при эксплуатации (изменение динамики значений анализируемых параметров в сторону увеличения / уменьшения, величина изменения (например, в процентах)). Классификация состояний исследуемого объекта, с целью идентификации его предаварийных ситуаций.

2. Выбор метода исследования из числа допустимых математических методов реализации РПАС по необходимому набору признаков.

3. Создание банка функций с заданными критериями как набора признаков возможных внеплановых событий как предаварийных состояний при эксплуатации газоконденсатных скважин.

4. Разработка математической модели как набор алгоритмических и программных средств для РПАС при эксплуатации скважин.

В ходе рассмотрения процесса эксплуатации скважин были обнаружены и рассмотрены внеплановые события, обусловленные гидратообразованием.

Примером исходных данных для моделирования являются следующие значения параметров для скважин кустов 202, 206, 207 (Рисунки 1-3). Для сравнения графиков все данные нормированы. В качестве значения нормы для давления принято значение в 160 атм., для температуры 50 С, расход 20000 м<sup>3</sup>/сут. Значения снимаются каждые 2 часа. Данный период назовем «тик».



На Рисунках 1 и 2 на начальной стадии наблюдается отсутствие потока данных, что соответствует значению, равному нулю. При анализе графиков давления до и после устройства регулирования наблюдается общая корреляция. Следует заметить, что уровень давления после устройства регулирования ниже уровня давления до него, но при этом давление во время наблюдаемой эксплуатации подвержено убывающему тренду. При этом есть участки, где корреляции не наблюдается. Определенная связь наблюдается между давлением до устройства регулирования и расходом. На начальном этапе замеров виден участок с резким падением давления, которому соответствует скачек расхода газа, что легко объясняется физическими процессами. Но при этом катастрофическое падение давления до нуля на каждом из графиков сопровождается падением расхода до нуля и падением температуры до чрезвычайно низких показателей. Скорее всего это объясняется проблемой в работе датчиков.




Рисунок 1 – Данные по скважине 2022 куста 202  
Figure 1 – Data for well 2022 of pad 202




Рисунок 2 – Данные по скважине 2061 куста 206  
Figure 2 – Data for well 2061 of pad 206




Рисунок 3 – Данные по скважине 2073 куста 207  
Figure 3 – Data for well 2073 of pad 207

В связи с тем, что исходные данные довольно объемные, решено использовать временные сверточные сети, которые не зависят от масштаба данных. Данные предварительно обработаны. Из выборки данных по давлению удалены все значения, описывающие резкие падения, вплоть до нуля, которые предварительно классифицированы как нефизичные в условиях задачи. Кроме этого, удалены значения, характеризующие резкое возрастание значений давления. Из выборки отобраны значения, превышающие среднее значение, взятое от 100 соседних значений с порогом в 20% от среднего. Начальное значение времени смещено в зону реально снимаемых данных. Исходные и обработанные данные представлены на Рисунке 4.



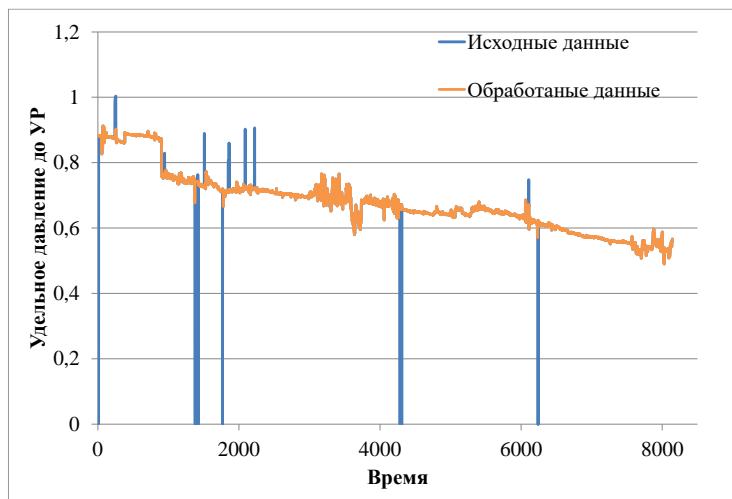


Рисунок 4 – График давления до регулирующего устройства в скважине 2022  
Figure 4 – Graph of pressure to the control device in well 2022

Сохраненные данные выборки представляют записи параметров каждые 2 часа. Для апробации данные разделены на две выборки:

- обучающая выборка, используемая для обучения модели – первые 90% данных общей выборки;
- тестовая выборка, используемая для проверки прогнозных свойств сети – последние 10% данных общей выборки.

График распределения выборок представлен на Рисунке 5.

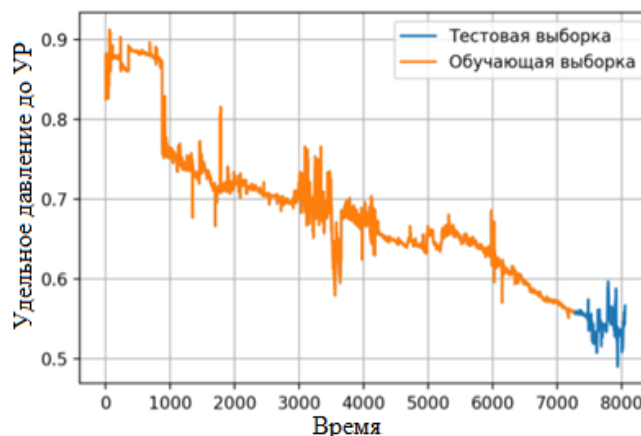


Рисунок 5 – График обучающей и тестовой выборки скважины 2022  
Figure 5 – Graph of training and test sample of well 2022

Для увеличения скорости сходимости при обучении для выбранных нейронных сетей выбран один из популярных оптимизаторов под названием Adam (adaptive moment estimation) [17]. По заявлению авторов метода он основан на градиентах первого порядка, как и основные классические методы, но для увеличения скорости обучения используются градиентные моменты второго порядка. Метод рекомендован для нестационарных задач и задач с очень зашумленными и разреженными градиентами.

При моделировании использовались следующие параметры. Количество точек для окна экстраполяции равняется 24, что соответствует двум суткам для представленных данных.

Для обучения модели TCN (рисунок 6) использовались следующие индивидуальные параметры:

- количество фильтров в сверточных слоях, от которых зависит количество предсказаний и размер нейронной сети, равно 64;
- размер ядра, используемого в каждом сверточном слое, равен 4;
- в качестве функции активации нейрона использовалась линейная;
- количество эпох обучения; 100.

За время обучения значение ошибки стабилизировалось в области малых значений, что характеризует приемлемую обученность сети на представленных данных. Произведена экстраполяция данных с использованием обученной нейронной сети и сравнение с тестовой выборкой (рисунок 6). Средняя по модулю абсолютная ошибка для экстраполяции равна TCN Avg Loss: 0,00020761334896085782.

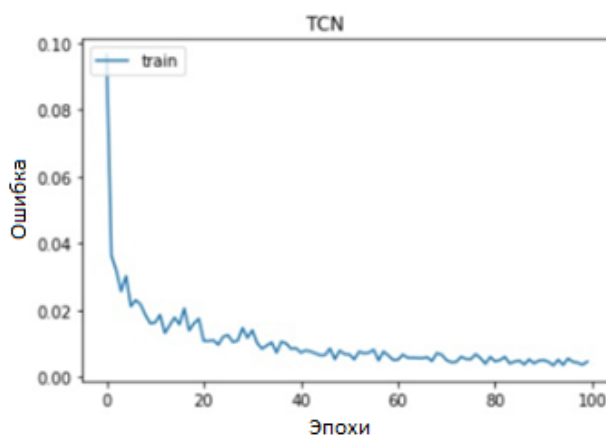


Рисунок 6 – Визуализация процесса обучения модели TCN  
 Figure 6 – Visualization of the TCN model learning process




Рисунок 7 – Результаты предсказания TCN на тестовой выборке  
 Figure 7 – Results of TCN prediction using the test set

Данные экстраполяции полностью повторяют поведение данных тестовой выборки, но при этом находятся выше исходных данных. Анализ значений абсолютных ошибок приведен на Рисунке 8.

Ошибки распределены по карманам из диапазонов значений, выбранных автоматически из всего набора. Характерно малое количество малых и больших по величине значений. При этом все ошибки имеют положительные значения.

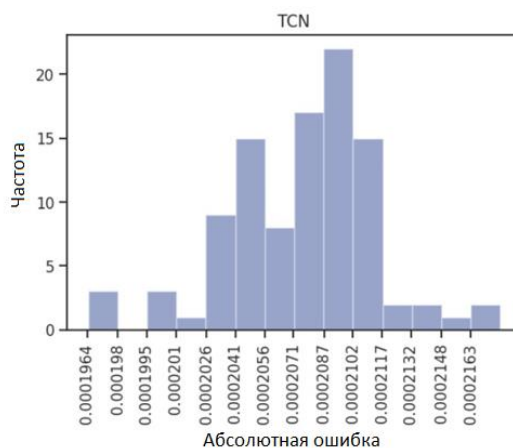


Рисунок 8 – Средняя абсолютная ошибка TCN  
 Figure 8 – TCN average absolute error

Настройка нейросети MLP в основном не отличается от TCN. Количество эпох также равняется 100. В качестве функции активации использовался выпрямляющий линейный узел (ReLU). Модель получилась легкой и переобучения не было обнаружено. На Рисунке 9 представлен график обучения модели MLP. Сходимость процесса оказалась чрезвычайно высокой.

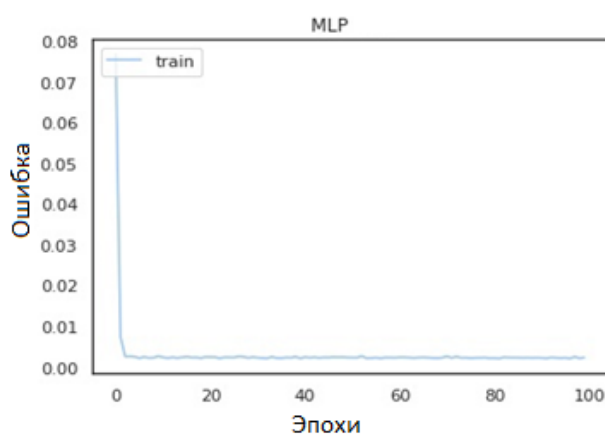


Рисунок 9 – График обучения модели MLP  
 Figure 9 – MLP Model Training Graph

С помощью обученной модели нейросети произведена экстраполяция данных тестовой выборки и результаты представлены на Рисунке 10. Следует отметить, что средняя по модулю абсолютная ошибка при экстраполяции MLP Avg Loss равна 0,000468.




Рисунок 10 – Результаты предсказания MLP на тестовой выборке  
Figure 10 – Results of MLP prediction using the test set

Как и для предыдущей модели наблюдается приемлемое совпадение тестовых данных и экстраполяции. Поведение ломаной экстраполяции полностью повторяет поведение тестовых данных, но при этом экстраполяционная кривая проходит ниже.

Для обучения модели LSTM использовались следующие индивидуальные параметры:

- в соответствии с особенностями модели задано положительное целое число, размерность выходного пространства, равное 32;
- в качестве функции активации использовался гиперболический тангенс (tanh);
- количество эпох обучения равно 70.

С помощью обученной модели нейросети произведена экстраполяция данных тестовой выборки и результаты представлены на Рисунке 11. Средняя по модулю абсолютная ошибка для экстраполяции LSTM Avg Loss равна 0,000540.

При экстраполяции данных этой моделью нейросети в начале участка наблюдается очень хорошее совпадение значений. Именно на этом участке абсолютные значения ошибок экстраполяции имеют как положительные, так и отрицательные значения (Рисунок 12). По мере продвижения по оси времени экстраполяция повторяет характер тестовых данных, но значения ошибки начинают заметно нарастать. Данный процесс виден на Рисунке 12 в виде правой части гистограммы. Скорее всего, это свидетельствует об особенности модели, связанной с наличием краткосрочной и долгосрочной «памяти».

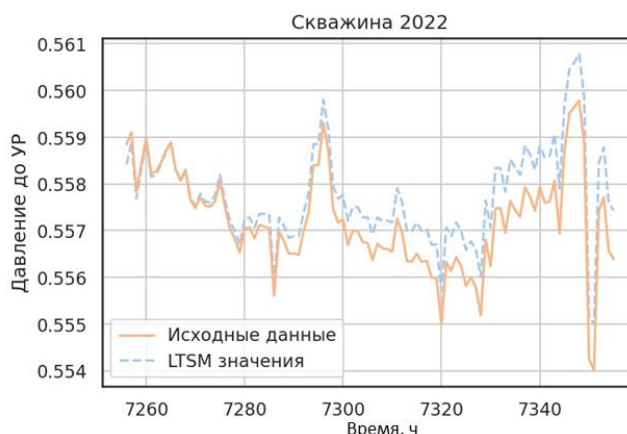


Рисунок 11 – Результаты предсказания LSTM на тестовой выборке  
Figure 11 – Results of LSTM prediction using the test set

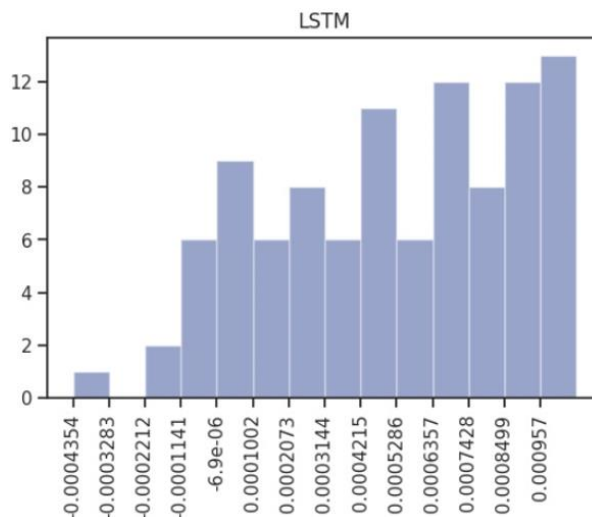


Рисунок 12 – Средняя абсолютная ошибка для LSTM  
Figure 12 – Average absolute error for LSTM

### Обсуждение

Установлено, что необходима предварительная обработка объемных временных рядов. Особенность данной обработки заключается в том, что исходные данные не только зашумлены, но и имеют «нефизические выбросы», когда соседние значения резко отличаются по величине. Предложено совмещать временные ряды давления и температуры, что позволяет практически полностью исключить аномальные выплески. Однако при отсутствии локальных данных по температуре такая обработка не может быть выполнена. Дополнительно предложено подготовку вести, ориентируясь на данные предыдущих периодов.

Проанализирована возможность применения для рассматриваемой задачи современных архитектур нейросетей, а именно: сверточных нейросетей – TCN, нейронных сетей прямого распространения – MLP, рекуррентных нейронных сетей – LSTM. Предложено для LSTM отказаться от функции активации, что позволяет обеспечить нейросеть «долговременной памятью» о хранимых значениях, что крайне важно для данной задачи. Кроме того, выполнено перекрестное сравнение скорости снижения ошибок при обучении сетей для обнаружения архитектуры, способной к «самообучению».

### Заключение

Большой объем потоков разнородных данных, полученных при мониторинге эксплуатации сложных технических систем, требует автоматизации процесса управления этими системами. Поскольку данные разнородные и могут быть зашумлены, либо на них накладываются технологические сбои при измерениях, наиболее перспективными методами автоматизации управления являются интеллектуальные системы.

В рамках проведенного исследования рассмотрены различные архитектуры нейронных сетей и установлено, что для задачи предупреждения аварийных ситуаций на объектах, представляющих важнейшее народнохозяйственное значение, возможно использовать сверточные нейросети – TCN, нейронные сети прямого распространения – MLP, рекуррентные нейронные сети – LSTM. В результате пришли к выводу, что для модели LSTM лучше отказаться от функции активации для обеспечения нейросети «долговременной памятью». Все модели были протестированы с использованием

обучающих данных со скважин «Восточный купол». Для всех моделей было получено приемлемое совпадение тестовых и экстраполяционных данных.

Предложено использовать алгоритм скользящих окон, при этом протяженность окон принять меняющейся величиной, а в перспективе работы – принять ее самонастраивающейся величиной в зависимости от структуры различных участков исходного временного ряда. Обнаружено, что в ряде случаев повышается точность прогноза. Скорее всего, это связано с выбором оптимального размера окна.

Таким образом, полученные предварительные результаты дают основание полагать, что временной горизонт предсказания поведения на скважине может достигать 48 часов при потенциальной ошибке не более 10 %. Отмечено, что данные величины существенно зависят от качества исходных временных рядов.

### СПИСОК ИСТОЧНИКОВ

1. Павлов С.Г. Разработка технологии оценки геоэкологической безопасности газопроводов в условиях возникновения аварийных ситуаций: дис. ... канд. техн. наук. М.: 2009. Доступно по: [http://miigaik.ru/science/councils/congregation / 09\\_05\\_21\\_pavlov.pdf](http://miigaik.ru/science/councils/congregation / 09_05_21_pavlov.pdf) (дата обращения: 30.10.2021).
2. Комашинский В.И., Смирнов Д.А. *Нейронные сети и их применение в системах управления и связи*. М.: Горячая линия – Телеком; 2002. 94 с.
3. Подольский А.К. Применение методов искусственного интеллекта в нефтегазовой промышленности. *Современная наука*. 2016;(3):33–36.
4. Нейросеть сможет оценить риски аварий на предприятиях нефтяной отрасли в Арктике. Доступно по: [https://minobrnauki.gov.ru/press-center/news/?ELEMENT\\_ID=40904](https://minobrnauki.gov.ru/press-center/news/?ELEMENT_ID=40904) (дата обращения: 15.11.2021).
5. Малкина В.Д., Кукаренко А.В. Система оптоволоконного мониторинга трубопроводов «ОМЕГА» с применением искусственного интеллекта. *Экологический вестник России*. 2020. Режим доступа: <https://omega.transneft.ru/press/articles/?id=36023> (дата обращения: 15.11.2021).
6. Автоматическая система контроля аварийных выбросов на химически опасных объектах (АСКАВ). Доступно по: <http://cit-avtomatika.ru/catalogue/avtomatizaciya/askav/> (дата обращения: 01.12.2021).
7. Вялышев А.И., Добров В.М., Долгов А.А., Зиновьев С.В., Файзулин Т.Ш. Система контроля аварийных ситуаций на объектах нефтегазодобычи в акваториях арктических морей. *Технологии гражданской безопасности*. 2013;37(3):16–21.
8. Многослойный перцептрон (Multilayered perceptron). Доступно по: <https://wiki.loginom.ru/articles/multilayered-perceptron.html> (дата обращения: 18.11.2021).
9. Долгая краткосрочная память. Доступно по: [https://neerc.ifmo.ru/wiki/index.php?title=Долгая\\_краткосрочная\\_память](https://neerc.ifmo.ru/wiki/index.php?title=Долгая_краткосрочная_память) (дата обращения: 18.11.2021).
10. Устройство регулирующее исполнительное УР. Доступно по: <https://p-sr.ru/products/ustrojstva-zapornye-krany-sharovye/ustrojstva-reguliruyushhie-ur/> (дата обращения: 15.11.2021).
11. Катаев К.А. Гидратообразование в трубопроводах природного газа. *Всероссийский журнал научных публикаций*. 2011;2(1).
12. Дорман В.Н., Баскакова Н.Т. Анализ состояния оборудования как инструмент снижения расходов на ремонты. *Экономический анализ: теория и практика*. 2011;(39).



13. Науменко А.П. *Теория и методы мониторинга и диагностики: Материалы лекций*. Омск: ОмГТУ; 2017. 154 с.
14. Dietterich T. Machine Learning for Sequential Data: A Review. *Structural, Syntactic, and Statistical Pattern Recognition*. 2002:15–30.
15. Fox M. Industrial Applications of Artificial Intelligence. *Robotics*. 1986:301–311.
16. Временные сверточные сети и прогнозирование. Доступно по: <https://ichi.pro/ru/vremennye-svertocnye-seti-i-prognozirovanie-102124506152164> (дата обращения: 18.11.2021).
17. A Method for Stochastic Optimization. Доступно по: <https://arxiv.org/abs/1412.6980> (дата обращения: 04.12.2021).

## REFERENCES

1. Pavlov S.G. Development of technology for assessing the geocological safety of gas pipelines in emergency situations: dis. ... Candidate of Technical Sciences. M.: 2009. Available by: [http://miigaik.ru/science/councils/congregation / 09\\_05\\_21\\_pavlov.pdf](http://miigaik.ru/science/councils/congregation / 09_05_21_pavlov.pdf) (accessed: 10/30/2021). (In Russ.)
2. Komashinsky V.I., Smirnov D.A. *Neural networks and their application in control and communication systems*. M.: Hotline – Telecom; 2002. 94 p. (In Russ.)
3. Podolsky A.K. Application of artificial intelligence methods in the oil and gas industry. *Modern science*. 2016;(3):33–36. (In Russ.)
4. The neural network will be able to assess the risks of accidents at oil industry enterprises in the Arctic. Available by: [https://minobrnauki.gov.ru/press-center/news/?ELEMENT\\_ID=40904](https://minobrnauki.gov.ru/press-center/news/?ELEMENT_ID=40904) (accessed: 11/15/2021). (In Russ.)
5. Malkina V.D., Kukarenko A.V. The OMEGA fiber-optic pipeline monitoring system with the use of artificial intelligence. *Ecological Bulletin of Russia*. 2020. Available by: <https://omega.transneft.ru/press/articles/?id=36023> (accessed: 15.11.2021). (In Russ.)
6. Automatic control system for emergency emissions at chemically hazardous facilities (ASKAV). Available by: <http://cit-avtomatika.ru/catalogue/avtomatizaciya/askav/> (date of reference: 01.12.2021). (In Russ.)
7. Vyalyshev A.I., Dobrov V.M., Dolgov A.A., Zinoviev S.V., Fayzulin T.S. Emergency control system at oil and gas production facilities in the waters of the Arctic seas. *Technologies of civil safety*. 2013;37(3):16–21. (In Russ.)
8. Multilayer perceptron (Multilayered perceptron). Available by: <https://wiki.loginom.ru/articles/multilayered-perceptron.html> (accessed: 11/18/2021). (In Russ.)
9. Long short-term memory. Available by: [https://neerc.ifmo.ru/wiki/index.php?title=Long-term\\_memory](https://neerc.ifmo.ru/wiki/index.php?title=Long-term_memory) (accessed: 11/18/2021). (In Russ.)
10. The device regulating the executive UR. Available by: <https://p-sr.ru/products/ustrojstva-zapornye-krany-sharovye/ustrojstva-reguliruyushhie-ur> (accessed: 15.11.2021). (In Russ.)
11. Kataev K.A. Hydrate formation in natural gas pipelines. *All-Russian Journal of Scientific publications*. 2011;2(1). (In Russ.)
12. Dorman V.N., Baskakova N.T. Equipment condition analysis as a tool to reduce repair costs. *Economic analysis: theory and practice*. 2011;(39). (In Russ.)
13. Науменко А.П. *Theory and methods of monitoring and diagnostics: Materials of lectures*. Омск: ОмSTU; 2017. 154 p. (In Russ.)
14. Dietterich T. Machine Learning for Sequential Data: A Review. *Structural, Syntactic, and Statistical Pattern Recognition*. 2002:15–30.

15. Fox M. Industrial Applications of Artificial Intelligence. *Robotics*. 1986;301–311.
16. Temporary convolutional networks and forecasting. Available by: <https://ichi.pro/ru/vremennye-svertocnye-seti-i-prognozirovanie-102124506152164> (accessed: 11/18/2021).
17. A Method for Stochastic Optimization. Available by: <https://arxiv.org/abs/1412.6980> (accessed: 04.12.2021).

## ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Боровской Игорь Георгиевич**, доктор физико-математических наук, профессор Томского государственного университета систем управления и радиоэлектроники, Томск, Российская Федерация.  
*e-mail*: [igdoca@mail.ru](mailto:igdoca@mail.ru)  
ORCID: [0000-0003-2707-7203](https://orcid.org/0000-0003-2707-7203)

**Igor Georgievich Borovskoy**, Doctor of Physical and Mathematical Sciences, Professor of Tomsk State University of Control Systems and Radioelectronics, Tomsk, Russian Federation.

**Шельмина Елена Александровна**, кандидат физико-математических наук, доцент Томского государственного университета систем управления и радиоэлектроники, Томск, Российская Федерация.  
*e-mail*: [eashelmina@mail.ru](mailto:eashelmina@mail.ru)  
ORCID: [0000-0002-6278-5961](https://orcid.org/0000-0002-6278-5961)

**Elena Aleksandrovna Shelmina**, Candidate of Physical and Mathematical Sciences, Associate Professor of Tomsk State University of Control Systems and Radioelectronics, Tomsk, Russian Federation.

**Афанасьева Инга Геннадьевна**, старший преподаватель Томского государственного университета систем управления и радиоэлектроники, Томск, Российская Федерация.  
*e-mail*: [ledyghost@yandex.ru](mailto:ledyghost@yandex.ru)

**Inga Gennadievna Afanasyeva**, Senior Lecturer at Tomsk State University of Control Systems and Radioelectronics, Tomsk, Russian Federation.

**Матолыгин Андрей Анатольевич**, старший преподаватель Томского государственного университета систем управления и радиоэлектроники, Томск, Российская Федерация.  
*e-mail*: [matolygin.andrei@yandex.ru](mailto:matolygin.andrei@yandex.ru)  
ORCID: [0000-0001-5737-1329](https://orcid.org/0000-0001-5737-1329)

**Andrey Anatolyevich Matolygin**, Senior Lecturer at Tomsk State University of Control Systems and Radioelectronics, Tomsk, Russian Federation.

*Статья поступила в редакцию 27.05.2022; одобрена после рецензирования 28.06.2022; принята к публикации 13.07.2022.*

*The article was submitted 27.05.2022; approved after reviewing 28.06.2022; accepted for publication 13.07.2022.*