



Научная статья
УДК 622.692.4

Интеллектуальный мониторинг состояний объектов трубопроводного транспорта углеводородов с применением нейросетевых технологий

М.Ю.ЗЕМЕНКОВА✉, Е.Л.ЧИЖЕВСКАЯ, Ю.Д.ЗЕМЕНКОВ

Тюменский индустриальный университет, Тюмень, Россия

Как цитировать эту статью: Земенкова М.Ю., Чижевская Е.Л., Земенков Ю.Д. Интеллектуальный мониторинг состояний объектов трубопроводного транспорта углеводородов с применением нейросетевых технологий // Записки Горного института. 2022. Т. 258. С. 933-944. DOI: 10.31897/PMI.2022.105

Аннотация. Государственной стратегической целью Российской Федерации является обеспечение безопасности критических технологий и отраслей, имеющих важное значение для развития нефтегазовой промышленности страны. Работа посвящена созданию отечественной технологии интеллектуального мониторинга состояния промышленных объектов транспорта и хранения нефти и газа. Разработана концепция современной системы мониторинга и управления безопасностью, ориентированная на обеспечение комплексного инженерного контроля с применением интегрированных автоматизированных систем управления, для создания интеллектуального методологического обеспечения импортозамещающих технологий. Предложен комплекс апробированных алгоритмов для мониторинга и управления процессами и состоянием технических систем с применением модульных управляющих роботизированных комплексов. Разработаны оригинальные интеллектуальные модели для мониторинга безопасности и классификации техногенных событий и состояний. В качестве примера представлены алгоритмы мониторинга интеллектуального критерия безопасности для объектов и процессов трубопроводного транспорта углеводородов. В разработке учтены требования федерального законодательства и потребности отрасли.

Ключевые слова: интеллектуальный мониторинг; управление; нефтепровод; газопровод; надежность; безопасность; система управления

Благодарность. Исследование выполнено при поддержке национального проекта «Наука и университеты» Министерства науки и высшего образования Российской Федерации (FEWN-2021-0012).

Поступила: 30.09.2022

Принята: 28.11.2022

Онлайн: 29.12.2022

Опубликована: 29.12.2022

Введение. Актуальность задачи цифровизации, интеллектуализации ключевых отраслей промышленности и создания современных технологий управления процессами и объектами отмечена в самых современных научных работах [1-3] и ряде федеральных документов: национальной программе «Цифровая экономика РФ» (утверждено Президиумом Совета при Президенте РФ по стратегическому развитию и национальным проектам, протокол от 04.06.2019 № 7), Стратегии развития информационного общества в Российской Федерации на 2017-2030 годы (указ Президента РФ от 09.05.2017 г. № 203), Национальной стратегии развития искусственного интеллекта на период до 2030 года (указ Президента РФ от 10.10.2019 № 490), постановлении Правительства РФ «О проведении эксперимента по внедрению системы дистанционного контроля промышленной безопасности» (от 31.12.2020 № 2415) и других документах по безопасности и экологии, отраслевых программах [4, 5].

Кафедрой транспорта углеводородных ресурсов Тюменского индустриального университета предложена принципиально новая концепция системы интеллектуального нейросетевого инженерного контроля, прогнозирования и предупреждения техногенных событий, внештатных ситуаций, инцидентов, аварий и оптимизации технических решений при управлении технологическими процессами опасных производственных объектов трубопроводного транспорта нефти и газа



[6-8]. Стратегической целью создания такой системы является обеспечение эффективного управления объектами трубопроводного транспорта как одной из важнейших отраслей промышленности государства, которая, в свою очередь, потребует решения серьезных емких задач, связанных с разработкой методологического аппарата, комплекса методик и алгоритмов, программной реализацией. Кроме того, в условиях современной экономики особенно остро стоит проблема импортозамещения. В мировой практике существуют некоторые разработки, посвященные решению отдельных задач при создании моделей с интеллектуальной составляющей: для оценки надежности поставок нефтепродуктов [6, 7]; идентификации дефектов при оценке технического состояния [8, 9]; оценки динамики коррозионных процессов [9-11]; прогнозирования гидравлических характеристик потоков [12-14], гидравлических машин [15], а также проектного положения конструкций [16-18]. Однако единая концепция комплексного интеллектуального управления безопасностью нефтегазовой отраслью не представлена или показана фрагментарно [19].

Проблемам создания систем мониторинга надежности и безопасности процессов транспорта углеводородов на объектах магистральных трубопроводов посвящено большое количество отечественных научных трудов [20-22], однако вопрос создания оперативного автоматизированного предиктивного мониторинга техногенных событий и состояний при транспорте нефти и газа пока открыт. Для учета различных угроз безопасности и факторов снижения надежности в системе магистральных нефтегазопроводов применяется и развивается достаточно широкий спектр диагностических средств мониторинга [23-25], в том числе для функционирования в реальном времени [24-26], а также моделей для прогнозирования параметров режимов, утечек, потерь [27-29]. В работах [30-32] решены научные задачи интеллектуальной оценки параметров систем транспорта углеводородов, однако для мониторинга состояний и универсального решения задач управления безопасностью известные в отрасли модели не применимы.

По данным официальных отчетов Ростехнадзора, в последние годы наблюдается стабильное снижение аварийности на объектах магистрального транспорта и хранения нефти и газа (рис.1), однако инциденты происходят, а аварии могут достигать масштаба национальной катастрофы (разлив дизельного топлива в районе Норильска 29 мая 2020 г.). Это свидетельствует о необходимости не только мониторинга фоновых рисков [20], но и создания систем именно автоматизированного предиктивного мониторинга с функциями управления и предупреждения техногенных событий и их развития на базе современных моделей с учетом всех угроз. Разработка и использование универсального интеллектуального подхода в сочетании с существующими научными разработками для решения задач, и его системное применение в управлении [33-35] позволяет создать систему управления состоянием объектов нового поколения.

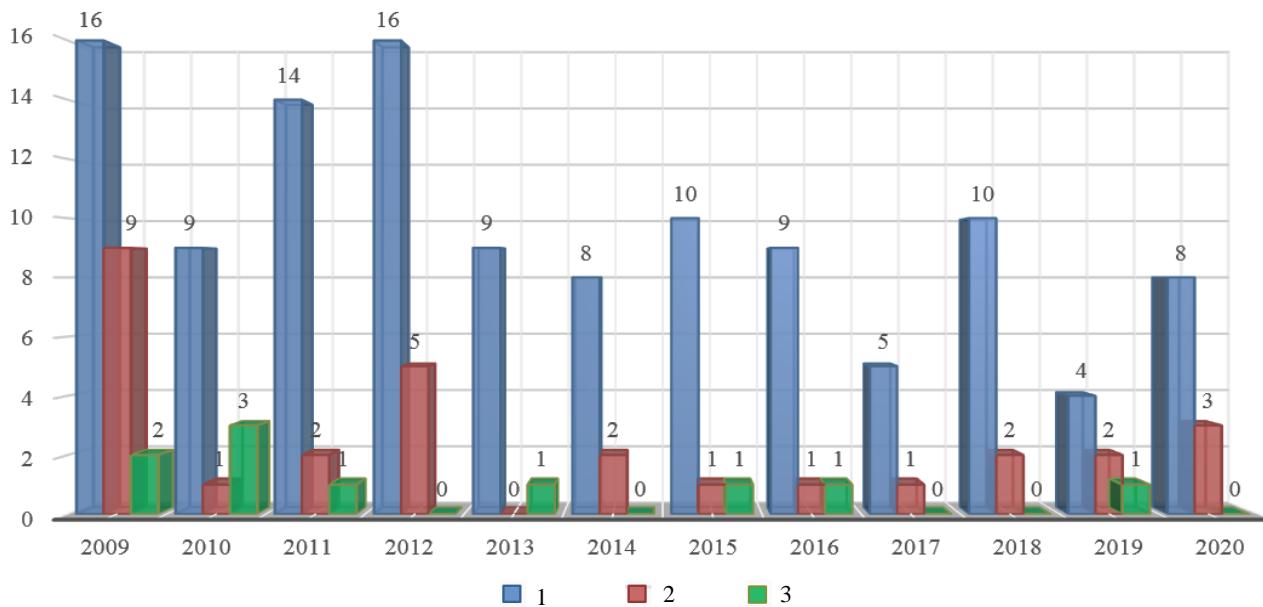


Рис.1. Динамика аварий на объектах магистрального трубопроводного транспорта

1 – газопроводы; 2 – нефтепроводы; 3 – нефтепродуктопроводы



Несмотря на новую волну научного интереса к нейронным сетям в связи с увеличением мощности вычислительных машин и средств моделирования, разросшиеся базы архитектур нейронных сетей различного назначения, некоторый опыт реализации при решении задач управления эффективностью и безопасностью [31, 32] объектов магистральных газо- и нефтепроводов, задача создания универсальных систем предиктивного мониторинга безопасности состояний и процессов в настоящее время является актуальной.

Методы. Разработанная система является оригинальной и направленной на обеспечение независимости от иностранных поставщиков и информационной безопасности технологий управления. В работе рассмотрены некоторые особенности авторского методологического обеспечения для создания систем предиктивного интеллектуального мониторинга безопасности. Задача мониторинга в режиме реального времени отличается тем, что необходимо учитывать регулярные обновления нормативной документации на федеральном уровне, по-прежнему ориентированной на оценку безопасности с учетом актуальной информации о надежности и обеспечение эффективности процессов. Методологический подход подразумевает использование имеющейся в отрасли, наработанной поколениями, научной базы с применением нейросетевых технологий. Использован критериальный подход и предложен комплекс критериев, отражающих свойства объектов нефтегазопроводов как технического объекта. Так, например, при обеспечении безопасности учитываются не только критерии, специфичные для сложных комплексов инженерно-технических сооружений, но и поток внутренних и внешних угроз, надежность, эффективность технологических процессов, факторы взаимодействия с техногенной, антропогенной и природной средами.

Системный анализ требований актуальной нормативно-технической документации и результатов научных разработок в области надежности, безопасности, практики мониторинга нефтегазопроводов показал, что на производстве ограничиваются оценкой работоспособности, технического состояния, остаточного ресурса. Задачи оценки и мониторинга безопасности сводятся к декларированию, а оценка надежности – к расчету точечных оценок показателей и их фиксации на некоторый срок.

Таким образом, для создания универсальной, но все же специализированной, в соответствии со свойствами объектов, системы управления требуется база моделей точечного контроля и моделей реального времени. Несмотря на наличие на предприятиях баз данных большого объема, каждый модуль управляющей системы должен быть четко структурирован и обеспечен методической базой для обработки потока данных, к примеру о режимах транспорта нефти и газа, режимах работы технологического оборудования, техническом состоянии, энергопотреблении, трудозатратах, проведенных ремонтах и затраченных ресурсах, объемах запасных частей и материалах, качестве работ, сроках эксплуатации и т.д. Задачи прогнозирования состояний опасных производственных объектов и их подсистем очень сложны с физико-технической точки зрения, но могут быть частично решены с использованием интеллектуального подхода.

Для решения задач управления интеллектуальными методами авторами разработана универсальная методика путем создания нейросетевых моделей для мониторинга безопасности объектов трубопроводного транспорта нефти и газа (рис.2). Преимуществом методики является то, что в зависимости от задач, поставленных на первом этапе, может быть сформирован индивидуальный алгоритм решения. Методика создания модели предусматривает восемь основных этапов, на каждом из которых принимается научное решение, обоснованное технологическими особенностями производственных процессов, объектов, системным подходом к цели и задачам мониторинга, математическими методами решения и потенциалом нейросетей.

На первом этапе выполняется постановка ключевой задачи мониторинга. Так, например, классификация техногенных событий (согласно Руководству по безопасности № 29, утвержденному приказом Ростехнадзора от 24.01.2018) соответствует пункту 1.2 (рис.2), а задача предиктивного мониторинга – пункту 1.4. При постановке математических моделей с учетом возможностей диагностической базы формируется оптимальная модель нейросети с гиперпараметрами, видом обучения, и таким образом формируется индивидуальная траектория, позволяющая решить задачу. Рассмотрим пример реализации нейросетевых моделей для классификации техногенных событий и прогнозирования интеллектуального критерия безопасности.



Рис.2. Алгоритм реализации методики создания нейросетевой модели для системы мониторинга безопасности объектов (Z_i – показатель безопасности; y_i – сканируемый системой мониторинга параметр)

В настоящее время применяется оценка риска по системе показателей. Особенno актуальным для создания систем мониторинга в режиме реального времени является критериальный подход, предложенный профессором Н.А.Махутовым [1, 4]. На основании критериального подхода авторами статьи предложено ввести понятие комплексного интеллектуального критерия безопасности

$$K_b = f(K_{b_{v_1}}, K_{b_{v_2}}, \dots, K_{b_{v_m}}), \quad (1)$$

где $K_{b_{v_1}}, K_{b_{v_2}}, \dots, K_{b_{v_m}}$ – критерии безопасности по системе признаков и по группам, установленным федеральными законами (механическая (ФЗ № 384), информационная (ФЗ № 149), пожарная (ФЗ № 123), экологическая (ФЗ № 7), национальная (ФЗ № 390 и т.д.); v_i – вид безопасности; i – порядковый номер, $i \in [1; m]$.

Функциональная зависимость для оценки интеллектуального критерия безопасности (критерий верхнего уровня) будет иметь следующий вид:



$$K_6^u = OUTt(K_{\delta v_1}, K_{\delta v_2}, \dots K_{\delta v_m}), \quad (2)$$

где $OUTt(K_{\delta v_1}, K_{\delta v_2}, \dots K_{\delta v_m})$ – выходной сигнал нейронной сети произвольной архитектуры для объекта t .

Критерий безопасности следующего иерархического уровня определяется набором входных критериев безопасности входного уровня или характеристик объекта (процесса)

$$K_{\delta vi} = f(Z_{vi_1}, Z_{vi_2}, Z_{vi_3}, \dots Z_{vi_n}), \quad K_{\delta vi} = OUT(Z_{vi_1}, Z_{vi_2}, Z_{vi_3}, \dots Z_{vi_n}), \quad (3)$$

где $Z_{vi_1}, Z_{vi_2}, Z_{vi_3}, \dots Z_{vi_n}$ – критерии безопасности базового уровня (оцениваются по параметрам процессов и систем, сканируемых диагностическими и диспетчерскими системами).

Границные условия для применения модели оценки безопасности

$$K_6^u = 1 \text{ при всех } K_{\delta vi} = 1; \quad K_6^u = 0 \text{ при всех } K_{\delta vi} = 0; \quad (4)$$

начальные условия определяются максимальным значением в момент начала эксплуатации $K_{60}^u = 1$, на момент запуска системы мониторинга в произвольный момент времени (фактическое значение):

$$K_{60}^u = K_{60'}^u. \quad (5)$$

При классификации техногенных событий (например, по пяти группам (согласно Руководству по безопасности № 29, утвержденному приказом Ростехнадзора от 24.01.2018 г.), должно удовлетворяться условие, при котором:

$$\begin{aligned} K_6^u &= > K_{64}^u \text{ при всех } K_{\delta vi} \in E_{5+}; \\ K_{64}^u &> K_{63}^u > K_{62}^u \text{ при всех } K_{\delta vi} \in E_{4+}; \\ K_{63}^u &> K_{62}^u > K_{61}^u \text{ при всех } K_{\delta vi} \in E_{3+}; \\ K_{62}^u &> K_{61}^u > K_{60}^u \text{ при всех } K_{\delta vi} \in E_{2+}; \\ K_{61}^u &> K_{60}^u \geq 0 \text{ при всех } K_{\delta vi} \in E_{1+}, \end{aligned}$$

где $E_{1+}, E_{2+}, E_{3+}, E_{4+}$ – множество состояний, каждое из которых представляет собой группу техногенных событий уровня опасности 1, 2, 3, 4; E_{5+} – состояние безопасной эксплуатации при отсутствии отклонений и угроз.

Задаемся пороговыми значениями $K_{64}^u, K_{63}^u, K_{62}^u, K_{61}^u$ для последующей интеллектуальной оценки весовых коэффициентов факторов или коэффициентами значимости синаптических связей для последующего интеллектуального вычисления пороговых значений.

Для инициации нейронной сети, согласно математическим и техническим основам [36], предварительно обязательно проводится эвристический анализ ситуации. Анализ возможностей диагностического аппарата определяет число сенсоров – количество нейронов входного слоя, количество сканируемых свойств – число скрытых слоев. Так, например, при мониторинге режимов количество сенсоров будет идентично количеству сканируемых параметров процесса, при оценке технического состояния – количеству оцениваемых характеристик при диагностике; при оценке ресурса – количеству сканируемых параметров коррозионного процесса, напряженно-деформируемого состояния и факторов деградации, технического состояния линейной части трубопровода – на основе результатов диагностирования с учетом толщинометрии, профилометрии, характеристик дефектов и т.д. В итоге, с системной точки зрения, определенный набор исходных данных соответствует некоторому заключению, которое нейросеть должна идентифицировать и которое может быть выражено как комплексная оценка или состояние.

Для оценки динамики авторами введено понятие коэффициента изменения критерия безопасности в процессе эксплуатации

$$C = K_{\delta \phi} / K_{\delta \text{пр}}, \quad (7)$$

где $K_{\delta \text{пр}}$ – комплексный критерий безопасности объекта с проектными свойствами; $K_{\delta \phi}$ – комплексный критерий безопасности объекта с фактическими свойствами в режиме эксплуатации; $K_{\delta \text{пр}} = K_{\delta \phi} = 1$ – проектное значение для нового объекта; $C \in (0;1]$ $K_{\delta \phi} \in (0;1]$ – область определения функций.

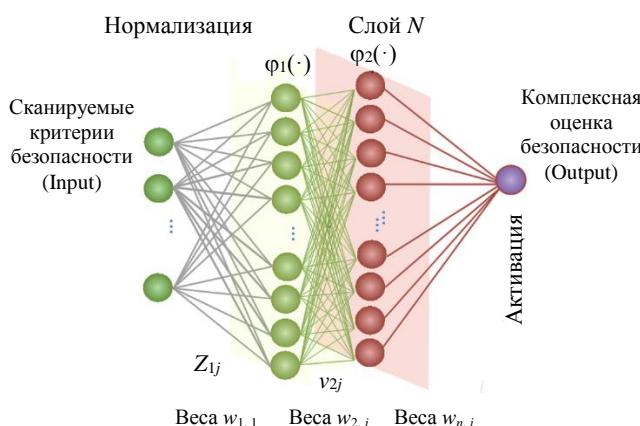


Рис.3. Универсальная схема нейросети для комплексной оценки с учетом значимости входных критериев

критериев должен отражать фактическое изменение технического состояния объекта по отношению к проектному, при обосновании соответствия – нормативному).

Для комплексной оценки безопасности режимов транспорта углеводородов (или любых операций) предложен критерий безопасности технологического процесса по функции (рис.3), зависящей от системы переменных:

$$K_{б.т.п} = f(Z_{p_1}, Z_{p_2}, Z_{p_3}, \dots Z_{p_n}), \quad K_{б.т.п} = OUT(Z_{p_1}, Z_{p_2}, Z_{p_3}, \dots Z_{p_n}), \quad (9)$$

где $Z_{p_1}, Z_{p_2}, Z_{p_3}, \dots Z_{p_n}$ – критерии безопасности базового нулевого уровня (полученные на основании измеряемых и формализованных параметров процессов и систем).

Рассмотрим в качестве примера, как могут быть реализованы модели для оценки безопасности технологического процесса нефтеперекачивающей станции. Разработанные алгоритмы и модели могут быть применены в произвольной среде программирования, обеспечивающей алгоритмы работы нейронных сетей или математический аппарат машинного обучения. Рассмотрим некоторые особенности реализации и верификации моделей оценки безопасности и идентификации состояний в среде Matlab.

Контрольная выборка идентификационной сети содержала банк данных объемом более 1000 примеров, сканированных при диспетчерском контроле и управлении технологическими режимами транспорта нефти на примере магистральной насосной станции в различных вариантах загрузки. Нейронная сеть обучалась на ретроспективной выборке о динамике комплекса параметров, соответствующей техногенным событиям 1, 2, 3, 4 и нормальной эксплуатации в состоянии 5, согласно действующей классификации техногенных событий для опасных производственных объектов. Строение обучающей выборки отражало реальные условия эксплуатации, когда основную часть времени объект находится в нормальном режиме эксплуатации, т.е. в состоянии 5, и при начальных отклонениях от оптимальных параметров процессов – в состоянии 4. Объем выборки нахождения в состоянии 3, 2, 1 идентифицирован по аварийным параметрам оборудования. Аварий и инцидентов в процессе работы допущено не было, согласно требованиям безопасности; пороговые значения идентификаторов устанавливались экспертным путем на основании ретроспективного анализа событий и требований нормативных документов по эксплуатации объектов нефтеперекачивающей станции.

Для оценки состояний системы и идентификации техногенных событий по уровню опасности была инициирована интеллектуальная модель на базе многослойного перцептрона прямого распространения с количеством нейронов, равным (и кратным) числу сенсоров на входящем слое нейрона, а именно – количеству сканируемых режимных параметров. Так, на входе получен поток данных для девяти нейронов, равный размерности входной матрицы. Входная матрица данных содержала критерии безопасности нулевого уровня на базе параметров технологического процесса трубопроводного транспорта углеводородов, на выходе – пять состояний по уровню опасности техногенных событий, архитектура – двухслойный перцептрон (рис.4, а). Стоит отметить, что

Так, регламентированный рисковый подход может быть синхронизирован и дополнен интеллектуальным подходом с учетом самых различных свойств объекта. Например, по мнению авторов, для учета фактического технического состояния и надежности нефтегазопроводов целесообразно рассчитывать показатели риска, принимая во внимание интеллектуальный критерий механической безопасности

$$K_{м.б} = f(Z_{M_1}, Z_{M_2}, Z_{M_3}, \dots Z_{M_n}), \quad (8)$$

где $Z_{M_1}, Z_{M_2}, Z_{M_3}, \dots Z_{M_n}$ – критерии механической безопасности нулевого уровня на конкретном промышленном объекте (каждый из



двухслойный перцептрон – оптимальная базовая архитектура, позволяющая обеспечить заданную точность идентификации. В ряде случаев необходимо и целесообразно усложнение модели, увеличение количества слоев и нейронов в слое, однако возникает риск характерной для нейронных сетей ошибки переобучения, требуется анализ показателей обучения для обеспечения максимальной сходимости и минимальной ошибки. Для иллюстрируемых моделей проводилась оптимизация гиперпараметров сетей и показаны наиболее приемлемые архитектуры. Так, нейросетевая модель была апробирована в среде программирования Matlab с применением градиентного метода оптимизации Левенберга – Марквардта [36]. Установлено, что при моделировании пороговых значений необходимо установить критические значения и правила, при которых значения коэффициентов будут соответствовать пороговым. По мнению авторов, целесообразны два способа принятия пороговых значений – нормирование и вычисление нейронной сетью.

Из производственной практики известно, что одно и то же отклонение некоторых режимных параметров от оптимальных или нормативных при различных сочетаниях с другими может быть как безопасным, так и фатальным. Именно для таких случаев полный производственный опыт, экспертные оценки специалистов, модельные выборки должны быть учтены при формировании базы данных. Обновляемые пакетным или последовательным образом базы данных должны учитывать все возможные случаи, которые могут привести к инциденту, аварии, катастрофе и, разумеется, предсказать такие события на ранних стадиях. Так, полностью обученная на фактических и нормативных данных нейронная сеть идентифицирует входящее в режиме реального времени состояние системы по набору входных данных, помещая единицу на позицию в матрице, соответствующую техногенному состоянию определенного уровня опасности. Извлечение синаптических связей в полносвязной нейронной сети может быть выполнено для любого слоя сети.

Результаты. Результаты оптимизации нейросетевой модели по выборке показали сходимость нейронной сети на 68 эпохе со скоростью обучения 0,711, стартовым градиентом 0,602. Из графика кривой валидации (рис.4, б) видно, что минимальное значение кросс-энтропии достигается при количестве эпох – 62, последующее увеличение количества эпох может привести к ошибке переобучения, поэтому оптимизируются параметры обучения: минимизируются кросс-энтропия и ошибка классификации. Таким образом, процент ошибки сети минимизирован (равен нулю) (рис.5), т.е. ошибки классификации отсутствуют. Формы кривых истинности идентификаций ROC (Receiver Operator Characteristic) свидетельствуют о высокой точности модели (рис.5), ошибки классификатора минимальны. Ошибки идентификации в данной модели могут возникнуть при появлении неизвестных интеллектуальной системе примеров состояний в потоке данных. При качественном формировании обучающей выборки с учетом предварительного системного многофакторного анализа технической системы, возможных сценариев развития техногенных событий, а также своевременном пакетном или последовательном обновлении ошибки идентификации практически исключаются.

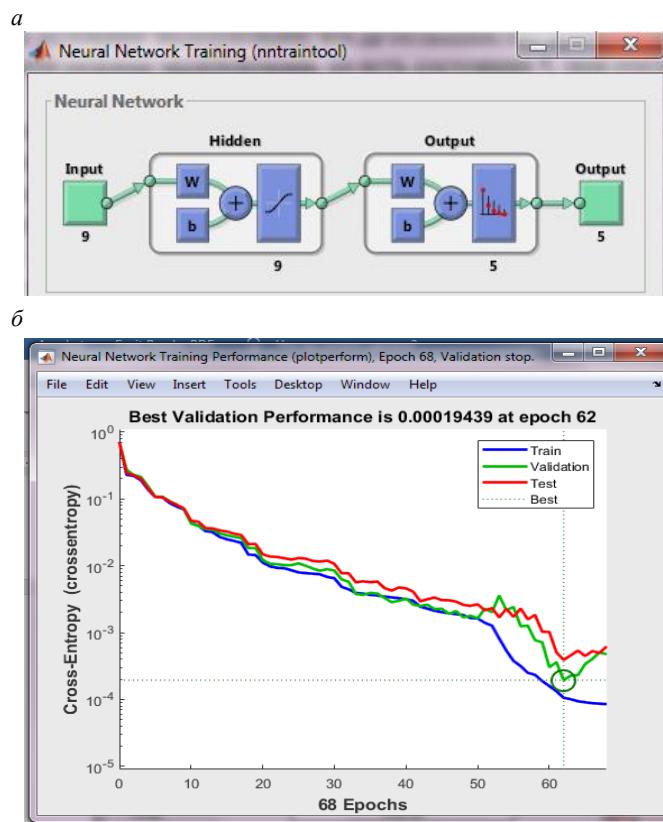


Рис.4. Пример работы нейросети для идентификации состояний:
а – архитектура нейронной сети с девятью скрытыми нейронами и двумя скрытыми слоями в среде Matlab;
б – оптимизация показателей обучения – валидация

Результаты оптимизации нейросетевой модели по выборке показали сходимость нейронной сети на 68 эпохе со скоростью обучения 0,711, стартовым градиентом 0,602. Из графика кривой валидации (рис.4, б) видно, что минимальное значение кросс-энтропии достигается при количестве эпох – 62, последующее увеличение количества эпох может привести к ошибке переобучения, поэтому оптимизируются параметры обучения: минимизируются кросс-энтропия и ошибка классификации. Таким образом, процент ошибки сети минимизирован (равен нулю) (рис.5), т.е. ошибки классификации отсутствуют. Формы кривых истинности идентификаций ROC (Receiver Operator Characteristic) свидетельствуют о высокой точности модели (рис.5), ошибки классификатора минимальны. Ошибки идентификации в данной модели могут возникнуть при появлении неизвестных интеллектуальной системе примеров состояний в потоке данных. При качественном формировании обучающей выборки с учетом предварительного системного многофакторного анализа технической системы, возможных сценариев развития техногенных событий, а также своевременном пакетном или последовательном обновлении ошибки идентификации практически исключаются.

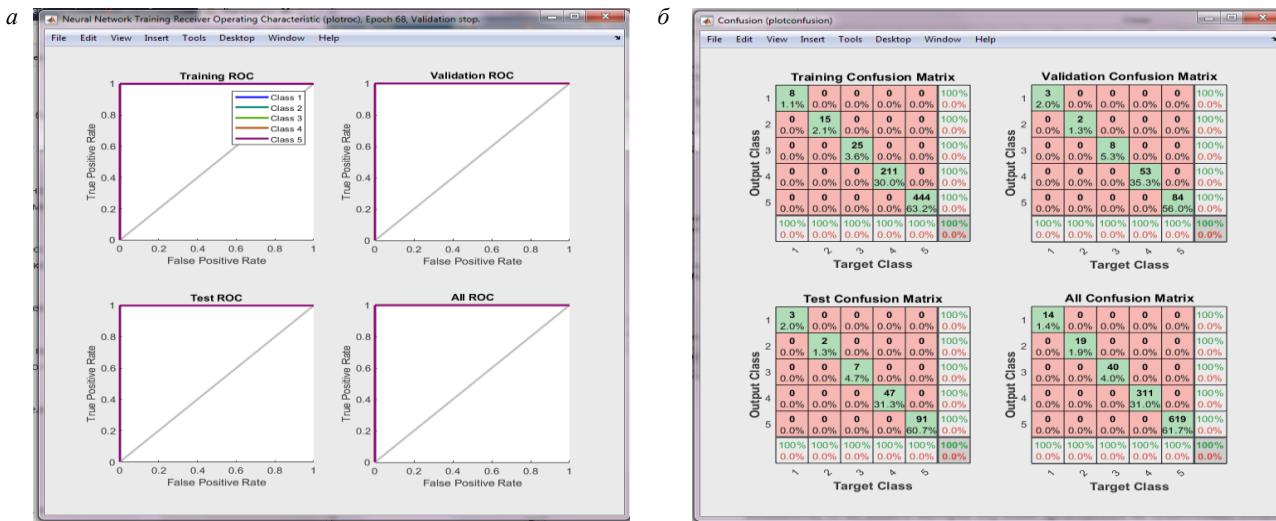


Рис.5. Результаты обучения идентификационной нейросети: *а* – линии истинности идентификации; *б* – ошибки классификатора (красные квадраты)

Рассмотрим пример другой возможной функции нейросетевого анализа, которая необходима как для сравнения уровня безопасности, так и для принятия решений и ранжирования объектов. Для комплексной оценки безопасности в работе была инициирована нейронная сеть для модели с одним вычисляемым выходом. Для интеллектуальной комплексной оценки критерия безопасности принят архитектура многослойного перцептрона с количеством сенсоров, равным количеству сканируемых параметров и факторов угроз. Для обучения модели количество входных параметров было принято равным девяти признакам (показателям режима работы объекта), в слое – двум. Сходимость сети для данной модели была достигнута на 158 эпохе со скоростью обучения 2,0 и градиентом 4,29, высоким коэффициентом регрессии (0,999), отсутствием ошибок валидации, со среднеквадратичной ошибкой обучения $2,98 \cdot 10^{-11}$, ошибкой тестирования $1,29 \cdot 10^{-2}$ и ошибкой обучения $2,98 \cdot 10^{-11}$, что является высоким показателем.

Рассмотрим следующую функцию, которая имеет особо важное значение для осуществления прогнозирования параметров, состояния и предупреждения нежелательных событий, внештатных ситуаций, инцидентов и аварий. Для решения данных задач была научно обоснована и инициирована нейронная сеть прогнозирования временных рядов и состояний нефтегазопроводов на базе рекуррентной нейронной сети архитектуры NARX (non-linear autoregressive with exogenous inputs model).

Построенная модель прогнозирования в режиме реального времени на базе временного ряда представляет собой рекуррентную нейросеть с одним входом и смещением. Особенностью такой модели является то, что вектор сигнала, подаваемый на сенсорный слой многослойного перцептрона, представляет собой данные входного сигнала произвольного происхождения, характеризующие состояние системы, и выходного сигнала функции в предыдущие моменты времени. В таких моделях для минимизации ошибки и обеспечения сходимости рядов увеличивается количество слоев и их размерность по сравнению с сетями классификации и аппроксимации. При обосновании структуры с увеличением количества слоев происходит снижение ошибок прогнозирования. Особенностью архитектуры NARX является возможность подачи вспомогательного ряда как с отставанием, так с подкреплением (дополнительной информацией для прогнозирования). Нейросети с подкреплением имеют особое значение для решения задач обеспечения мониторинга эффективности технологических процессов с учетом не только структуры транспортных потоков, но и их экономических и технологических доходов и ущербов, что особенно важно для создания оптимальных путей на графах принятия решений по управлению процессами, техническим обслуживанием, ремонтом технологического оборудования, линейной части.

В качестве примера рассмотрим результаты обучения нейронной сети для прогнозирования временного ряда критерия безопасности технологического процесса в произвольных нестационарных режимах эксплуатации системы транспорта жидкых углеводородов (по оси абсцисс указаны



часы от начала мониторинга и формирования обучающей выборки). Как видно из графика (рис.6), при плавном изменении показателей точность предсказания модели корреляционно значима: высокие коэффициенты регрессии, низкие значения ошибки автокорреляции $6 \cdot 10^{-5}$. Гистограмма ошибок максимальна при модуле ошибок 0,003-0,005.

Анализ технологических процессов и диспетчерских операций показывает, что при стационарных процессах точность прогнозирования весьма высока, а значения отклонений отклика максимальны в точках изменения режима в связи с детерминированным вмешательством в работу системы или с человеческим фактором, предсказать которые невозможно. С физико-технической точки зрения нейросеть запоминает поведение системы в целом в различных ситуациях и по динамике комплекса параметров предсказывает следующие возможные варианты развития события, прогнозируя уровень опасности. Архитектура экспертной системы предусматривает, что диспетчер по безопасности видит не только целевой график, но и может проанализировать поведение подсистем (рис.7).

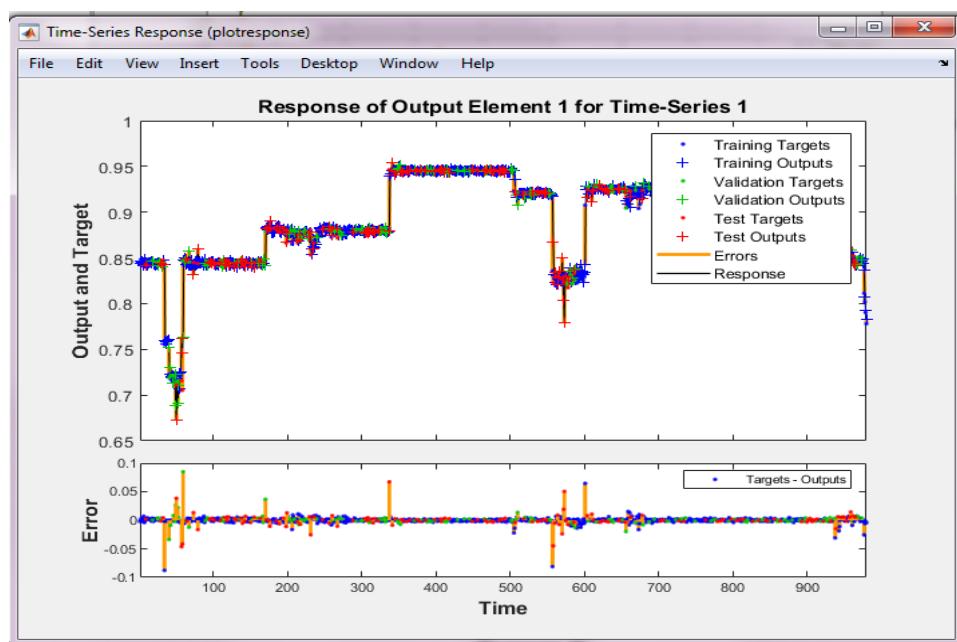


Рис.6. Отклик нейронной сети и ошибка отклика при прогнозировании временного ряда

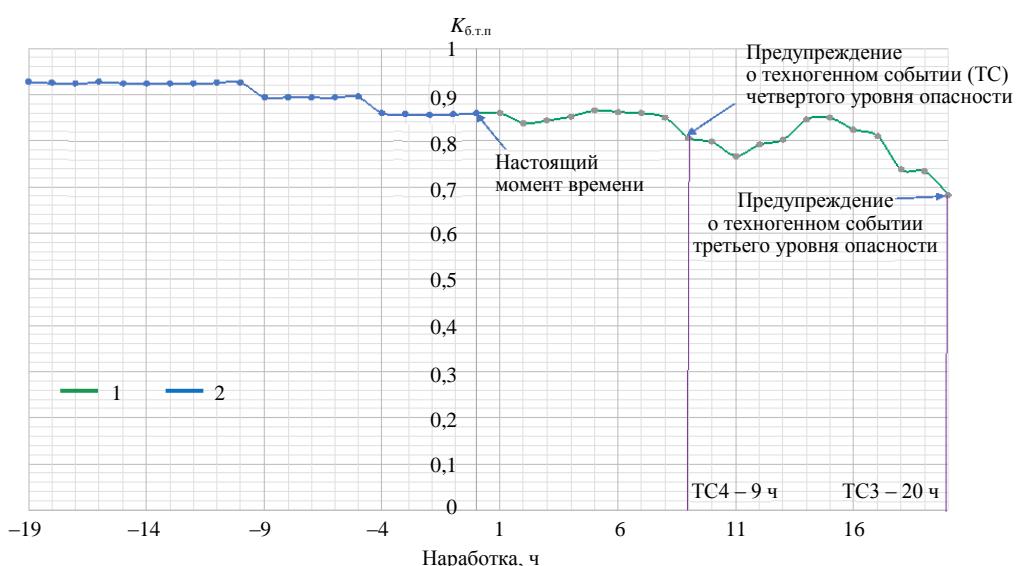


Рис.7. Пример графического изображения фрагмента прогнозирования критерия безопасности технологического процесса рекуррентной нейронной сетью

1 – прогноз нейронной сети; 2 – фактический ряд



Таким образом, можно спрогнозировать значения параметров безопасности по комплексу параметров на определенный промежуток времени вперед. Такие прогнозы, несомненно, помогут оперативно-диспетчерскому персоналу в принятии решений, особенно при внештатных ситуациях. Практика показывает, что опыт высококвалифицированного оперативно-диспетчерского персонала в обязательном порядке целесообразно не только учитывать и транслировать, но и использовать для роботизации, цифровизации и разработки систем поддержки принятия решений в специализированных модульных экспертных системах. Авторская модель нейросетевой оценки позволяет осуществлять интеллектуальный предиктивный мониторинг в режиме онлайн на базе системы критериев.

Обсуждение результатов. Установлено, что нейронные сети могут быть с высокой степенью эффективности использованы для прогнозирования техногенных событий и параметров процессов. Архитектура, гиперпараметры нейронной сети зависят от характера изучаемого процесса, объема и качества обучающих выборок, функциональных связей внутри технической системы. При соответствующей постановке модели и программировании результаты обучения моделей характеризуются высокими коэффициентами регрессии (0,99), низкой среднеквадратичной ошибкой обучения (10^{-4} - 10^{-3}), низкими ошибками классификации (0 %) и валидации ($(5\text{--}8)\cdot10^{-3}$). Оригинальные интеллектуальные модели прогнозирования критериев безопасности для процессов трубопроводного транспорта с применением рекуррентных нейронных сетей целесообразно использовать в режиме реального времени с учетом потока входящей информации. Анализ результатов работы свидетельствует о том, что при создании каждой интеллектуальной аналитической системы для обеспечения точности прогнозирования важное значение имеют условия формирования выборки, обоснование архитектуры нейросети для каждой решаемой задачи с учетом индивидуальных свойств систем и процессов.

Показано, что разработанный подход позволяет реализовать минимум три функции: оценку безопасности, прогнозирование оценок и параметров, идентификацию состояний в настоящем и будущем. Интеллектуальная система позволяет идентифицировать состояние объекта на фактических и прогнозных данных, оценивая прогнозируемое время возникновения техногенного события с учетом входящих угроз, факторов деградации и результатов диагностики, составляющих сенсорный слой нейронной сети в любом масштабе времени.

Заключение. Авторами разработан комплекс многофакторных моделей идентификации, прогнозирования и классификации техногенных событий, построенный на системном нейросетевом анализе потока данных сенсорных нейронов многослойных перцептронов прямого распространения с обучением.

Результаты апробации моделей на станционных объектах и линейных участках магистрального транспорта углеводородов позволяют выполнять интеллектуальный мониторинг техногенных событий оперативно в режиме реального времени. Представляется возможность на высоком технологическом уровне реализовать и оптимизировать решения стратегии технического обслуживания по фактическому состоянию, а главное – своевременно определить и предупредить внештатные ситуации, инциденты, чрезвычайные ситуации и аварии любого масштаба. Реализация авторского методологического подхода при создании модульных систем управления состоянием объектов транспорта нефти и газа позволяет повысить оперативность и обоснованность принятия решений по управлению безопасностью производственными процессами с максимальной эффективностью.

ЛИТЕРАТУРА

1. Махутов Н.А., Черепанов А.П., Лисанов М.В. Задачи разработки и реализации системы управления промышленной безопасностью предприятия при эксплуатации технических устройств // Безопасность труда в промышленности. 2021. № 2. С. 15-19. DOI: 10.24000/0409-2961-2021-2-15-19
2. Лисин И.Ю., Короленок А.М., Колотилов Ю.В. Системный подход к формированию интегрированных энергетических систем на платформе интеллектуальных информационно-технологических решений // Нефтяное хозяйство. 2020. № 3. С. 36-40. DOI: 10.24887/0028-2448-2020-3-36-40
3. Ревазов А.М., Лежнев М.А. Влияние аварий на объектах трубопроводного транспорта нефти и нефтепродуктов на окружающую среду // Защита окружающей среды в нефтегазовом комплексе. 2021. № 6 (303). С. 12-17. DOI: 10.33285/2411-7013-2021-6(303)-12-17



4. Махутов Н.А., Гаденин М.М., Иванов В.И. Научно-методическая база технического диагностирования потенциально опасных промышленных объектов // Безопасность труда в промышленности. 2021. № 6. С. 7-14. DOI: 10.24000/0409-2961-2021-6-7-14
5. Лисанов М.В., Сумской С.И., Швыряев А.А. Неопределенности количественной оценки риска аварий на нефтегазовых объектах // Вести газовой науки. 2018. № 2 (64). С.125-134.
6. Huai Su, Jinjun Zhang, Enrico Zio et al. An integrated systemic method for supply reliability assessment of natural gas pipeline networks // Applied Energy. 2018. Vol. 209. P. 489-501. DOI: 10.1016/j.apenergy.2017.10.108
7. Qian Chen, Lili Zuo, Changchun Wu et al. Short-term supply reliability assessment of a gas pipeline system under demand variations // Reliability Engineering & System Safety. 2020. Vol. 202. № 107004. DOI: 10.1016/j.ress.2020.107004
8. Wan Yong, Wang Yongzhi, Yang Yong et al. Intelligent identification and classification methods of oil and gas pipeline defects by fluxgate magnetometry // Journal of Harbin Engineering University. 2021. Vol. 42. Iss. 9. P. 1321-1329. DOI: 10.11990/jheu.202005049
9. Hayward N., Portugal M. Machine Learning Image Analysis for Asset Inspection // SPE Offshore Europe Conference and Exhibition, 3-6 September 2019, Aberdeen, UK. SPE-195773-MS. DOI: 10.2118/195773-MS
10. Wasim M., Djukic M.B. External corrosion of oil and gas pipelines: A review of failure mechanisms and predictive preventions // Journal of Natural Gas Science and Engineering. 2022. Vol. 100. № 104467. DOI: 10.1016/j.jngse.2022.104467
11. Stubelj I.R., Ruschmann H., Wold K., Gomnaes J.O. Pipeline Predictive Analytics Through On-Line Remote Corrosion Monitoring // Corrosion 2019, 24-28 March 2019, Nashville, Tennessee, USA. № NACE-2019-12899.
12. Brünenberg K., Vogt D., Ihring M. Additional Functionalities Of Model Based Leak Detection Systems To Improve Pipeline Safety And Efficiency // Pipeline Technology Journal. 2020. Iss. 1. P. 38-44.
13. Ghorbani B., Ziabasharhagh M., Amidpour M. A hybrid artificial neural network and genetic algorithm for predicting viscosity of Iranian crude oils // Journal of Natural Gas Science and Engineering. 2014. Vol. 18. P. 312-323. DOI: 10.1016/j.jngse.2014.03.011
14. Hankun Wang, Yunfei Xu, Bowen Shi et al. Optimization and intelligent control for operation parameters of multiphase mixture transportation pipeline in oilfield: A case study // Journal of Pipeline Science and Engineering. 2021. Vol. 1. Iss. 4. P. 367-378. DOI: 10.1016/j.jpse.2021.07.002
15. Tao Zhang, Hua Bai, Shuyu Sun. Intelligent Natural Gas and Hydrogen Pipeline Dispatching Using the Coupled Thermodynamics-Informed Neural Network and Compressor Boolean Neural Network // Processes. 2022. Vol. 10. № 2. DOI: 10.3390/pr10020428
16. Kraidi L., Shah R., Matipa W., Borthwick F. An investigation of mitigating the safety and security risks allied with oil and gas pipeline projects // Journal of Pipeline Science and Engineering. 2021. Vol. 1. Iss. 3. P. 349-359. DOI: 10.1016/j.jpse.2021.08.002
17. Li Xin, Bai Mingzhou, He Bohu et al. Safety analysis of landslide in pipeline area through field monitoring // Journal of Testing and Evaluation. 2022. Vol. 50. Iss. 6. DOI: 10.1520/JTE20200751
18. Suzhen Li, Chen Wei, Xinghua Peng. Safety Monitoring of Buried Pipeline with Socket Joints Subjected to Ground Deformation Using MEMS Inclinometers // Journal of Pipeline Systems Engineering and Practice. 2019. Vol. 10. Iss. 2. № 04019008. DOI: 10.1061/(ASCE)PS.1949-1204.0000380
19. Mohd Nazmi bin Mohd Ali Napiah, Hambali bin Chik. Revolutionising Pipeline Safety: Intelligent Weldment Inspection Decision Support System // Pipeline Technology Journal. 2019. Vol. 2. P. 38-42.
20. Гражданкин А.И., Печёркин А.С., Самусева Е.А. и др. О фоновых уровнях аварийных опасностей на опасных производственных объектах // Безопасность труда в промышленности. 2019. № 10. С. 50-56.
21. Ревазов А.М., Савушкина В.Н. Совершенствование методов обеспечения антитеррористической безопасности магистральных трубопроводов // Труды Российского государственного университета нефти и газа имени И.М.Губкина. 2019. № 4 (297). С. 127-137. DOI: 10.33285/2073-9028-2019-4(297)-127-137
22. Белостоцкий М.А., Куньлинь Л., Короленок А.М., Короленок В.А. Формирование интеллектуальной системы управления ремонтом на линейной части магистральных нефтепроводов // Наука и технологии трубопроводного транспорта нефти и нефтепродуктов. 2022. Т. 12. № 4. С. 368-375. DOI: 10.28999/2541-9595-2022-12-4-368-375
23. Васильев Г.Г., Джаялов А.А., Леонович И.А. Деформационный мониторинг строительных конструкций площадочных объектов нефтегазового комплекса на многолетнемерзлых грунтах // Транспорт и хранение нефтепродуктов и углеводородного сырья. 2020. № 5-6. С. 34-39. DOI: 10.24411/0131-4270-2020-6-34-39
24. Рудианов Г.В., Крапивский Е.И., Данильев С.М. Оценка характеристик сигналов при поиске пустот в грунте под бетонными плитами радиолокационными станциями подповерхностного зондирования // Записки Горного института. 2018. Т. 231. С. 245-253. DOI: 10.25515/PMI.2018.3.245
25. Усманов Р.Р., Чуккалов М.В., Романов И.А. и др. Практические аспекты применения мобильных систем цифровой радиографии // Газовая промышленность. 2022. № 8 (836). С. 66-74.
26. Горбань Н.Н., Васильев Г.Г., Сальников А.П., Шитов С.И. Разработка схемы размещения сканерных станций при наземном лазерном сканировании резервуаров с учетом требований к погрешности результатов измерений // Нефтяное хозяйство. 2020. № 2. С. 74-78. DOI: 10.24887/0028-2448-2020-2-74-78
27. Васильев Г.Г., Леонович И.А., Левин С.Н., Писаревский В.М. Потенциальные риски потерь нефтепродуктов при хранении и анализ путей их снижения // Безопасность труда в промышленности. 2020. № 5. С. 87-93. DOI: 10.24000/0409-2961-2020-5-87-93
28. Лурье М.В. Математическое моделирование процессов трубопроводного транспорта нефти, нефтепродуктов и газа. М.: Нефть и Газ, 2003. 336 с.
29. Николаев А.К., Фетисов В.Г., Лыков Ю.В. Экспериментальные исследования определения расхода газа при аварийной утечке на линейном участке газопровода // Трубопроводный транспорт: теория и практика. 2017. № 2 (60). С. 14-17.
30. Алекперова С.Т., Ревазов А.М. Практика применения технологий искусственного интеллекта при планировании мероприятий по обеспечению безопасности объектов добычи и транспорта углеводородов // Территория Нефтегаз. 2022. № 1-2. С. 40-44.
31. Шаммазов И.А. Определение показателей технического состояния газоперекачивающих агрегатов с применением нейронных сетей // Транспорт и хранение нефтепродуктов и углеводородного сырья. 2012. № 2. С. 34-37.



32. Токарев Д.В. Развитие теории и методов управления промышленной безопасностью на предприятиях трубопроводного транспорта углеводородов: Автoref. дис. ... д-ра техн. наук. Уфа: Институт проблем транспорта энергоресурсов, 2011. 46 с.
33. Земенкова М.Ю. Методы снижения технологических и экологических рисков при транспорте и хранении углеводородов. Тюмень: Тюменский индустриальный университет, 2019. 397 с.
34. Мусеев Б.В., Земенков Ю.Д., Чекардовский М.Н. и др. Аспекты надежности и диагностики нефтегазовых объектов. Тюмень: Тюменский индустриальный университет, 2019. 423 с.
35. Земенкова М.Ю. Системный анализ и технологический мониторинг надежности и безопасности при транспорте и хранении углеводородов. Тюмень: Тюменский индустриальный университет, 2017. 252 с.
36. Хайкин С. Нейронные сети. М.: Вильямс, 2018. 1104 с.

Авторы: **М.Ю.Земенкова**, д-р техн. наук, доцент, *mizemenkova@mail.ru*, <https://orcid.org/0000-0002-8106-0683> (Тюменский индустриальный университет, Тюмень, Россия), **Е.Л.Чижевская**, канд. экон. наук, доцент, <https://orcid.org/0000-0003-0158-3538> (Тюменский индустриальный университет, Тюмень, Россия), **Ю.Д.Земенков**, д-р техн. наук, профессор, <https://orcid.org/0000-0002-8784-4163> (Тюменский индустриальный университет, Тюмень, Россия).

Авторы заявляют об отсутствии конфликта интересов.