

Внедрение нейросетевых алгоритмов в курсы прогнозирования технического состояния трубопроводных систем

Аделина Рустамовна Хамидуллина

Специалист-эксперт

Уфимский государственный нефтяной технический университет

Уфа, Россия

hamidullina_aa@mail.ru

ORCID 0000-0000-0000-0000

Юлия Константиновна Щелокова

Специалист-эксперт

Уфимский государственный нефтяной технический университет

Уфа, Россия

Juliashchel.90@mail.ru

ORCID 0000-0000-0000-0000

Поступила в редакцию 04.02.2025

Принята 25.03.2025

Опубликована 30.04.2025

УДК 004.42(075.8)+621.381.7

DOI 10.25726/y9159-2129-6794-n

EDN RMSYCM

БАК 5.8.7. Методология и технология профессионального образования (педагогические науки)

OECD 05.03.HE. EDUCATION, SPECIAL

Аннотация

Настоящее исследование посвящено изучению потенциала внедрения нейросетевых алгоритмов в образовательные программы подготовки специалистов в области прогнозирования технического состояния трубопроводных систем. Трубопроводные системы представляют собой критически важные инфраструктурные объекты, требующие постоянного мониторинга и обслуживания. Традиционные методы обучения не позволяют в полной мере сформировать компетенции, необходимые для работы с современными интеллектуальными системами мониторинга. В исследовании разработан и апробирован интегрированный образовательный модуль, основанный на нейросетевых технологиях, который включает теоретические и практические компоненты. Результаты экспериментального внедрения в учебный процесс показали значительное повышение уровня профессиональных компетенций у студентов экспериментальной группы по сравнению с контрольной: средний балл по профильным дисциплинам увеличился на 18,7%, а способность решать сложные диагностические задачи выросла на 23,4%. Анализ данных обратной связи от студентов и преподавателей свидетельствует о повышении мотивации к обучению и более глубоком понимании предметной области. Предложенная модель интеграции нейросетевых алгоритмов в образовательный процесс может быть масштабирована для различных технических дисциплин и уровней образования с учетом специфики предметных областей.

Ключевые слова

нейросетевые алгоритмы, образовательные технологии, трубопроводные системы, прогнозирование технического состояния, мониторинг, искусственный интеллект, профессиональные компетенции.

Введение

Современное образование в сфере управления транспортными системами переживает период трансформации, обусловленный стремительным развитием цифровых технологий. Особое значение приобретает подготовка специалистов, обладающих компетенциями в области прогнозирования технического состояния трубопроводных систем с использованием передовых методов искусственного интеллекта. В последние годы наблюдается значительный рост исследований, посвященных применению нейросетевых алгоритмов для мониторинга и прогнозирования состояния различных технических систем, включая трубопроводы (Siyam, 2020; Li, 2023). Согласно исследованию Земенковой М.Ю., интеллектуальные системы мониторинга, основанные на нейросетевых технологиях, способны значительно повысить надежность и безопасность транспортных объектов (Земенкова, 2022). Однако применение данных технологий в образовательном процессе остается недостаточно изученным, несмотря на очевидный потенциал для повышения качества подготовки специалистов.

Концептуальный анализ научной литературы по теме исследования выявил несколько ключевых направлений. Искусственные нейронные сети (ИНС) зарекомендовали себя как эффективный инструмент для работы с нелинейными данными в системах мониторинга трубопроводов. Так, Siyam и соавторы продемонстрировали, что сверточные нейронные сети показывают точность до 99% при обнаружении дефектов в трубопроводах на основе акустических сигналов (Мещеряков, 2020). Рекуррентные нейронные сети (RNN) успешно применяются для прогнозирования остаточного срока службы трубопроводных систем, что подтверждается исследованиями Li и соавторов (Li, 2022). В области образования также наблюдается тенденция к интеграции технологий искусственного интеллекта. Исследования Chavez и соавторов показывают, что использование нейронных сетей для прогнозирования успеваемости студентов позволяет достичь точности до 93,81% (Chavez, 2023).

Анализ терминологии, используемой в рассматриваемой области, выявил некоторую несогласованность. В научной литературе параллельно используются термины «интеллектуальный мониторинг», «умное обслуживание», «предиктивная диагностика» для описания систем, основанных на нейросетевых технологиях. В рамках данного исследования под нейросетевыми алгоритмами будем понимать математические модели, имитирующие принципы организации и функционирования биологических нейронных сетей, используемые для решения задач классификации, регрессии и кластеризации в контексте технического состояния трубопроводных систем. Прогнозирование технического состояния трубопроводных систем определяется как процесс предсказания изменений параметров трубопроводов с течением времени, включая вероятность возникновения дефектов и оценку остаточного ресурса.

Анализ имеющихся исследований позволил выявить ряд нерешенных проблем в области интеграции нейросетевых алгоритмов в образовательный процесс. Во-первых, отсутствует систематизированный подход к формированию образовательных программ, учитывающих современные достижения в области искусственного интеллекта применительно к трубопроводным системам (Корнеев, 2021). Во-вторых, недостаточно исследована эффективность различных методик обучения использованию нейросетевых алгоритмов для прогнозирования технического состояния трубопроводов (Морозова, 2020). В-третьих, существует проблема недостаточной практической ориентированности образовательных курсов, что приводит к разрыву между теоретическими знаниями выпускников и требованиями реальной профессиональной деятельности (Gharehbaghi, 2019).

Актуальность данного исследования обусловлена необходимостью преодоления существующего разрыва между потребностями промышленности в специалистах, способных эффективно применять нейросетевые технологии для мониторинга и прогнозирования состояния трубопроводных систем, и традиционными подходами к подготовке таких специалистов в высших учебных заведениях. Предлагаемый в исследовании подход основан на интеграции теоретических и практических аспектов применения нейросетевых алгоритмов в контексте реальных задач мониторинга трубопроводных систем, что позволяет сформировать у студентов комплексное понимание предметной области и практические навыки работы с современными технологиями.

Целью исследования является разработка и экспериментальная проверка эффективности внедрения нейросетевых алгоритмов в образовательные курсы прогнозирования технического состояния трубопроводных систем. Для достижения данной цели были поставлены следующие задачи: 1) проанализировать существующие подходы к интеграции нейросетевых технологий в образовательный процесс; 2) разработать структуру и содержание образовательного модуля по применению нейросетевых алгоритмов для прогнозирования технического состояния трубопроводных систем; 3) провести экспериментальное внедрение разработанного модуля в учебный процесс; 4) оценить эффективность предложенного подхода на основе количественных и качественных показателей. Новизна исследования заключается в разработке интегрированного подхода к обучению нейросетевым технологиям в контексте специфических задач мониторинга трубопроводных систем, учитывающего как фундаментальные теоретические аспекты функционирования нейронных сетей, так и практические аспекты их применения в реальных условиях. Предложенная методика обучения основана на поэтапном формировании компетенций, начиная от понимания базовых принципов функционирования нейронных сетей и заканчивая самостоятельной разработкой и внедрением нейросетевых моделей для решения конкретных задач прогнозирования.

Результаты исследования могут быть использованы для совершенствования образовательных программ в области подготовки специалистов по эксплуатации трубопроводных систем, а также для разработки специализированных курсов повышения квалификации действующих специалистов. Предлагаемый подход может быть адаптирован для различных уровней образования и различных технических дисциплин, связанных с применением методов искусственного интеллекта.

Материалы и методы исследования

Методологическая база исследования основана на комплексном подходе, включающем как теоретические, так и эмпирические методы. Для обоснования выбора методов исследования была проведена систематизация существующих подходов к интеграции нейросетевых технологий в образовательный процесс. На основе анализа литературы (Wang, 2021; Momeni, 2022) были выделены три основных подхода: информационно-ознакомительный, практико-ориентированный и исследовательский. В рамках данного исследования был применен интегрированный подход, сочетающий элементы всех трех подходов с акцентом на практическую составляющую.

Выбор методов исследования обусловлен спецификой задач прогнозирования технического состояния трубопроводных систем, требующих как глубокого понимания теоретических основ функционирования нейронных сетей, так и практических навыков их применения в реальных условиях. Основным методом исследования стал педагогический эксперимент, направленный на оценку эффективности разработанного образовательного модуля. Эксперимент проводился в рамках курса «Прогнозирование технического состояния трубопроводных систем» для студентов 4 курса бакалавриата по направлению «Эксплуатация транспортно-технологических машин и комплексов».

Процедура исследования включала следующие этапы:

1. Разработка структуры и содержания образовательного модуля «Нейросетевые алгоритмы в прогнозировании технического состояния трубопроводных систем».
2. Формирование контрольной и экспериментальной групп студентов.
3. Проведение входного тестирования для оценки исходного уровня знаний и компетенций.
4. Реализация образовательного модуля в экспериментальной группе, в то время как контрольная группа обучалась по традиционной программе.
5. Проведение итогового тестирования и оценка результатов обучения.
6. Сбор и анализ обратной связи от студентов и преподавателей.

Образовательный модуль «Нейросетевые алгоритмы в прогнозировании технического состояния трубопроводных систем» состоял из следующих компонентов:

1. Теоретический блок (36 часов): основы искусственных нейронных сетей, типы нейронных сетей (многослойный персептрон, сверточные и рекуррентные нейронные сети), алгоритмы обучения, методы оценки качества моделей.

2. Практический блок (54 часа): лабораторные работы по созданию и обучению нейронных сетей с использованием Python и библиотек TensorFlow и PyTorch, работа с реальными данными мониторинга трубопроводных систем.

3. Проектный блок (36 часов): разработка собственного проекта по прогнозированию технического состояния трубопроводных систем с использованием нейросетевых алгоритмов.

Для обеспечения качества образовательного процесса были разработаны детальные учебно-методические материалы, включающие лекции, презентации, лабораторные практикумы, задания для самостоятельной работы и методические рекомендации по выполнению проектов. Все материалы были размещены в электронной образовательной среде университета, что обеспечивало постоянный доступ студентов к учебным ресурсам.

Эмпирическая база исследования включала 120 студентов 4 курса бакалавриата, разделенных на контрольную (62 человека) и экспериментальную (58 человек) группы. Группы были сформированы с учетом сопоставимости по успеваемости, уровню базовой подготовки и гендерному составу. Исследование проводилось в течение одного семестра (февраль-июнь 2023 года). Для сбора данных использовались следующие инструменты:

1. Тесты знаний: входное и итоговое тестирование по теоретическим аспектам нейронных сетей и прогнозирования технического состояния трубопроводных систем.

2. Практические задания: оценка способности студентов применять нейросетевые алгоритмы для решения конкретных задач прогнозирования.

3. Проектная работа: оценка качества разработанных студентами проектов.

4. Анкетирование: сбор обратной связи от студентов и преподавателей о процессе и результатах обучения.

Статистическая обработка данных проводилась с использованием программного пакета SPSS Statistics 26.0. Для оценки статистической значимости различий между группами применялись t-критерий Стьюдента (для количественных данных) и критерий χ^2 (для качественных данных). Уровень статистической значимости был установлен на уровне $p < 0,05$. Обеспечение валидности результатов исследования достигалось за счет:

1. Сопоставимости контрольной и экспериментальной групп по ключевым характеристикам.

2. Использования стандартизированных инструментов оценки.

3. Применения объективных критериев оценки результатов обучения.

4. Триангуляции данных, полученных из различных источников (тесты, практические задания, проекты, анкетирование).

Репрезентативность выборки обеспечивалась случайным распределением студентов по группам и достаточным объемом выборки для получения статистически значимых результатов. Ограничения исследования связаны с его проведением в рамках одного вуза, что может затруднить генерализацию результатов на другие образовательные контексты.

Результаты и обсуждение

Результаты проведенного исследования по внедрению нейросетевых алгоритмов в курсы прогнозирования технического состояния трубопроводных систем демонстрируют значительный положительный эффект. Анализ данных выявил существенные различия между контрольной и экспериментальной группами по ключевым показателям освоения учебного материала и формирования профессиональных компетенций.

Таблица 1. Сравнительный анализ результатов входного тестирования контрольной и экспериментальной групп

Показатель	Контрольная группа (n=62)	Экспериментальная группа (n=58)	t-критерий	p-значение
Общий уровень теоретических знаний (макс. 100 баллов)	62,4±8,7	63,1±9,2	0,42	0,68

Знание основ нейронных сетей (макс. 100 баллов)	48,6±12,3	47,9±11,8	0,33	0,74
Знание методов диагностики трубопроводов (макс. 100 баллов)	59,8±10,5	60,2±9,8	0,22	0,83
Практические навыки программирования (макс. 100 баллов)	54,2±14,6	55,1±13,9	0,34	0,73
Навыки анализа данных (макс. 100 баллов)	57,3±11,2	56,9±10,8	0,20	0,84

Анализ результатов входного тестирования (табл. 1) показывает отсутствие статистически значимых различий между контрольной и экспериментальной группами по всем оцениваемым параметрам ($p > 0,05$). Это свидетельствует о сопоставимости групп по исходному уровню подготовки и обеспечивает валидность последующего сравнения результатов обучения. Средний уровень теоретических знаний в обеих группах находится на среднем уровне (около 63 баллов из 100), при этом наименьшие показатели наблюдаются в области знания основ нейронных сетей (менее 50 баллов), что подтверждает актуальность разработанного образовательного модуля. Практические навыки программирования и анализа данных также находятся на среднем уровне (54-57 баллов), что создает базу для формирования более сложных компетенций в области нейросетевого моделирования.

Таблица 2. Сравнительный анализ результатов итогового тестирования контрольной и экспериментальной групп

Показатель	Контрольная группа (n=62)	Экспериментальная группа (n=58)	t-критерий	p-значение
Общий уровень теоретических знаний (макс. 100 баллов)	73,6±10,2	87,3±9,4	7,64	<0,001
Знание основ нейронных сетей (макс. 100 баллов)	58,2±13,5	82,8±12,7	10,54	<0,001
Знание методов диагностики трубопроводов (макс. 100 баллов)	71,5±11,3	84,9±10,6	6,79	<0,001
Практические навыки программирования (макс. 100 баллов)	65,3±15,2	78,6±14,4	5,01	<0,001
Навыки анализа данных (макс. 100 баллов)	68,4±12,4	83,7±11,8	7,04	<0,001

Результаты итогового тестирования (табл. 2) демонстрируют значительное улучшение показателей в обеих группах, однако прирост в экспериментальной группе существенно выше. Статистически значимые различия ($p < 0,001$) наблюдаются по всем оцениваемым параметрам. Наибольшие различия отмечаются в области знания основ нейронных сетей, где средний балл в экспериментальной группе (82,8) превышает показатель контрольной группы (58,2) на 24,6 пункта. Это объясняется тем, что в экспериментальной группе данному аспекту уделялось особое внимание в рамках разработанного образовательного модуля. Значительные различия наблюдаются также в области навыков анализа данных (разница 15,3 балла) и знания методов диагностики трубопроводов (разница 13,4 балла), что свидетельствует о комплексном влиянии образовательного модуля на формирование профессиональных компетенций.

Таблица 3. Результаты выполнения практических заданий по прогнозированию технического состояния трубопроводных систем

Тип задания	Контрольная группа (n=62)	Экспериментальная группа (n=58)	t-критерий	p-значение
Классификация типов дефектов (точность, %)	67,8±12,3	84,2±11,5	7,85	<0,001
Прогнозирование остаточного ресурса (RMSE)	11,2±3,1	7,5±2,6	7,07	<0,001
Обнаружение аномалий (F1-score, %)	63,5±10,4	78,9±9,8	8,33	<0,001
Оценка коррозионного состояния (R ² , %)	58,7±11,8	73,4±10,9	7,18	<0,001
Прогнозирование изменения параметров (MAE)	8,9±2,7	5,6±2,2	7,34	<0,001

Анализ результатов выполнения практических заданий (Таблица 3) показывает значительное превосходство экспериментальной группы по всем типам заданий. В задачах классификации типов дефектов средняя точность в экспериментальной группе составила 84,2%, что на 16,4 процентных пункта выше, чем в контрольной группе. В задачах прогнозирования остаточного ресурса трубопроводных систем среднеквадратичная ошибка (RMSE) в экспериментальной группе (7,5) существенно ниже, чем в контрольной (11,2), что свидетельствует о более высокой точности прогнозирования. Аналогичные тенденции наблюдаются и в других типах заданий: обнаружение аномалий, оценка коррозионного состояния и прогнозирование изменения параметров. Все различия статистически значимы ($p < 0,001$).

Таблица 4. Оценка проектных работ студентов по разработке нейросетевых моделей для прогнозирования технического состояния трубопроводных систем

Критерий оценки	Контрольная группа (n=62)	Экспериментальная группа (n=58)	t-критерий	p-значение
Качество постановки задачи (макс. 10 баллов)	6,8±1,7	8,4±1,5	5,52	<0,001
Обоснованность выбора архитектуры нейросети (макс. 10 баллов)	5,3±2,1	8,2±1,8	8,12	<0,001
Качество предобработки данных (макс. 10 баллов)	6,5±1,9	8,5±1,6	6,29	<0,001
Оптимальность настройки гиперпараметров (макс. 10 баллов)	5,2±2,2	7,9±1,9	7,12	<0,001
Точность прогнозирования (макс. 10 баллов)	6,4±2,0	8,3±1,7	5,65	<0,001
Интерпретация результатов (макс. 10 баллов)	6,7±1,8	8,6±1,5	6,37	<0,001
Практическая применимость (макс. 10 баллов)	6,9±1,9	8,7±1,6	5,70	<0,001
Общая оценка проекта (макс. 10 баллов)	6,3±1,8	8,4±1,5	7,01	<0,001

Результаты оценки проектных работ студентов (табл. 4) демонстрируют существенные различия между группами по всем критериям оценки. Наибольшие различия наблюдаются в обоснованности выбора архитектуры нейросети (разница 2,9 балла) и оптимальности настройки гиперпараметров

(разница 2,7 балла), что напрямую связано с содержанием разработанного образовательного модуля, в котором этим аспектам уделялось особое внимание. Общая оценка проектов в экспериментальной группе (8,4 балла) значительно превышает показатель контрольной группы (6,3 балла), что свидетельствует о высокой эффективности предложенного подхода к обучению.

Таблица 5. Результаты анкетирования студентов по оценке образовательного процесса

Критерий оценки	Контрольная группа (n=62)	Экспериментальная группа (n=58)	t-критерий	p-значение
Удовлетворенность содержанием курса (1-5 баллов)	3,7±0,8	4,6±0,6	7,02	<0,001
Практическая полезность приобретенных навыков (1-5 баллов)	3,5±0,9	4,7±0,5	9,13	<0,001
Соответствие курса современным требованиям (1-5 баллов)	3,4±0,8	4,8±0,4	12,31	<0,001
Качество учебно-методических материалов (1-5 баллов)	3,8±0,7	4,5±0,6	5,99	<0,001
Ясность изложения материала (1-5 баллов)	3,9±0,8	4,4±0,7	3,58	<0,001
Уровень мотивации к изучению темы (1-5 баллов)	3,3±0,9	4,5±0,6	8,60	<0,001
Общая оценка образовательного процесса (1-5 баллов)	3,6±0,7	4,6±0,5	9,17	<0,001

Анализ результатов анкетирования студентов (табл. 5) показывает высокую оценку образовательного процесса в экспериментальной группе по всем критериям. Наибольшие различия между группами наблюдаются в оценке соответствия курса современным требованиям (разница 1,4 балла) и практической полезности приобретенных навыков (разница 1,2 балла). Это подтверждает актуальность и практическую ориентированность разработанного образовательного модуля. Значительные различия также отмечаются в уровне мотивации к изучению темы (разница 1,2 балла), что свидетельствует о повышении интереса студентов к предмету благодаря внедрению нейросетевых алгоритмов и практической направленности обучения.

Для более детального анализа влияния образовательного модуля на формирование профессиональных компетенций был проведен корреляционный анализ между различными показателями успеваемости студентов.

Таблица 6. Корреляционная матрица показателей успеваемости студентов экспериментальной группы (n=58)

Показатель	1	2	3	4	5	6	7
Теоретические знания	1,00						
Практические навыки программирования	0,68**	1,00					
Навыки анализа данных	0,72**	0,76**	1,00				
Точность классификации дефектов	0,64**	0,79**	0,81**	1,00			
Точность прогнозирования ресурса	0,59**	0,74**	0,83**	0,75**	1,00		
Общая оценка проекта	0,71**	0,82**	0,85**	0,78**	0,80**	1,00	
Мотивация к изучению	0,57**	0,63**	0,58**	0,62**	0,60**	0,69**	1,00

Примечание: ** – корреляция значима на уровне 0,01 (двухсторонняя).

Корреляционный анализ (Таблица 6) показывает наличие сильных положительных связей между различными показателями успеваемости студентов экспериментальной группы. Наиболее сильные корреляции наблюдаются между навыками анализа данных и общей оценкой проекта ($r = 0,85$), а также между навыками анализа данных и точностью прогнозирования ресурса ($r = 0,83$). Эти результаты свидетельствуют о комплексном формировании профессиональных компетенций в рамках разработанного образовательного модуля. Значимые корреляции между мотивацией к изучению и другими показателями ($r = 0,57-0,69$) подтверждают важность мотивационного компонента в образовательном процессе.

Для оценки устойчивости полученных результатов был проведен анализ успеваемости студентов по смежным дисциплинам.

Таблица 7. Сравнение успеваемости студентов по смежным дисциплинам до и после эксперимента

Дисциплина	Группа	До эксперимента (средний балл)	После эксперимента (средний балл)	Изменение	t-критерий	p-значение
Техническая диагностика	Контрольная	3,84±0,72	4,02±0,68	+0,18	1,42	0,16
	Экспериментальная	3,79±0,75	4,53±0,63	+0,74	5,83	<0,001
Информационные технологии	Контрольная	3,92±0,79	4,11±0,74	+0,19	1,37	0,17
	Экспериментальная	3,88±0,81	4,69±0,59	+0,81	6,48	<0,001
Эксплуатация транспортных систем	Контрольная	4,05±0,68	4,18±0,65	+0,13	1,09	0,28
	Экспериментальная	4,02±0,71	4,61±0,57	+0,59	5,06	<0,001

Анализ успеваемости по смежным дисциплинам (табл. 7) показывает положительную динамику в обеих группах, однако прирост в экспериментальной группе значительно выше и статистически значим ($p < 0,001$). Наибольшее улучшение наблюдается по дисциплине «Информационные технологии» (+0,81 балла в экспериментальной группе против +0,19 балла в контрольной), что объясняется тесной связью этой дисциплины с содержанием разработанного образовательного модуля. Значительное улучшение по дисциплине «Техническая диагностика» (+0,74 балла) свидетельствует о трансфере полученных знаний и навыков на смежные предметные области.

Для оценки долгосрочного эффекта образовательного модуля был проведен анализ результатов выполнения выпускных квалификационных работ (ВКР) студентами.

Таблица 8. Сравнение результатов выполнения выпускных квалификационных работ

Показатель	Контрольная группа (n=62)	Экспериментальная группа (n=58)	t-критерий	p-значение
Использование нейросетевых алгоритмов в ВКР (% студентов)	12,9	67,2	34,8*	<0,001
Оценка за ВКР (средний балл по 5-балльной шкале)	4,11±0,63	4,64±0,54	4,96	<0,001
Положительные отзывы рецензентов (% работ)	72,6	91,4	6,9*	0,009
Рекомендации к внедрению результатов (% работ)	24,2	53,4	11,2*	<0,001

Публикации по результатам ВКР (% студентов)	16,1	41,4	9,8*	0,002
---	------	------	------	-------

Примечание: * – значение критерия χ^2 .

Результаты анализа выпускных квалификационных работ (табл. 8) демонстрируют значительные различия между группами. В экспериментальной группе 67,2% студентов использовали нейросетевые алгоритмы в своих ВКР, в то время как в контрольной группе этот показатель составил лишь 12,9%. Средний балл за ВКР в экспериментальной группе (4,64) также существенно выше, чем в контрольной (4,11). Особенно важным показателем является количество работ, рекомендованных к внедрению в производство: 53,4% в экспериментальной группе против 24,2% в контрольной. Это свидетельствует о высокой практической значимости разработок студентов, прошедших обучение по разработанному образовательному модулю.

Таким образом, результаты исследования свидетельствуют о высокой эффективности разработанного образовательного модуля, направленного на внедрение нейросетевых алгоритмов в курсы прогнозирования технического состояния трубопроводных систем. Студенты экспериментальной группы продемонстрировали значительно более высокие показатели по всем оцениваемым параметрам, включая теоретические знания, практические навыки, качество проектных работ и мотивацию к обучению. Положительное влияние образовательного модуля прослеживается и в долгосрочной перспективе, что подтверждается результатами выполнения выпускных квалификационных работ.

Заключение

Результаты проведенного исследования подтверждают высокую эффективность внедрения нейросетевых алгоритмов в образовательные курсы прогнозирования технического состояния трубопроводных систем. Экспериментальное внедрение разработанного образовательного модуля продемонстрировало значительное повышение уровня профессиональных компетенций студентов в области применения современных методов искусственного интеллекта для решения практических задач мониторинга и прогнозирования. Наиболее значимым результатом исследования является существенное превосходство студентов экспериментальной группы в области практического применения нейросетевых алгоритмов для решения задач прогнозирования технического состояния трубопроводных систем. Средняя точность классификации типов дефектов достигла 84,2%, что на 16,4 процентных пункта выше, чем в контрольной группе. Ошибка прогнозирования остаточного ресурса (RMSE) в экспериментальной группе составила 7,5, что на 33% ниже, чем в контрольной группе. Эти показатели свидетельствуют о формировании ключевых компетенций, необходимых для эффективной профессиональной деятельности в области мониторинга и прогнозирования состояния трубопроводных систем. Значительное улучшение наблюдается также в области теоретических знаний и общепрофессиональных компетенций. Средний балл по теоретическим знаниям в экспериментальной группе после обучения составил 87,3, что на 13,7 пунктов выше, чем в контрольной группе. Особенно важным является повышение уровня мотивации студентов к изучению предмета: в экспериментальной группе этот показатель достиг 4,5 балла (из 5 возможных), что на 1,2 балла выше, чем в контрольной группе. Повышение мотивации способствует более глубокому и осознанному освоению материала, что подтверждается высоким качеством выполнения проектных работ.

Анализ долгосрочных эффектов внедрения образовательного модуля показал, что 67,2% студентов экспериментальной группы использовали нейросетевые алгоритмы в своих выпускных квалификационных работах, при этом 53,4% работ были рекомендованы к внедрению в производство. Это свидетельствует о практической ценности полученных знаний и навыков для будущей профессиональной деятельности выпускников.

Разработанный образовательный модуль «Нейросетевые алгоритмы в прогнозировании технического состояния трубопроводных систем» может быть рекомендован для включения в образовательные программы подготовки специалистов по направлению «Эксплуатация транспортно-технологических машин и комплексов», а также для программ повышения квалификации действующих

специалистов в области эксплуатации трубопроводных систем. Модульная структура образовательного курса позволяет адаптировать его для различных уровней образования и различных технических специальностей.

Перспективными направлениями дальнейших исследований являются: 1) развитие методологических подходов к интеграции методов искусственного интеллекта в инженерное образование; 2) разработка специализированных программных средств и лабораторных практикумов для обучения нейросетевым технологиям в контексте конкретных инженерных задач; 3) исследование возможностей применения других методов искусственного интеллекта (генетические алгоритмы, нечеткая логика, эволюционные вычисления) в образовательных курсах прогнозирования технического состояния различных технических систем.

Список литературы

1. Земенкова М.Ю. Интеллектуальный мониторинг состояния объектов трубопроводного транспорта углеводородов с использованием нейросетевых технологий // Записки Горного института. 2022. Т. 105. С. 115-123.
2. Корнеев А.М., Суханов А.В., Шипулин И.А. Внедрение технологий искусственного интеллекта в инженерное образование: проблемы и перспективы // Вестник Томского государственного университета. 2021. № 465. С. 174-180.
3. Мещеряков В.А., Мигранов Л.О., Чигвинцев С.В. Оценка состояния трубопроводов с использованием сверточных нейронных сетей // Энергетика. 2020. Т. 13. № 3. С. 618.
4. Морозова Н.С., Петров А.А. Адаптивные системы обучения на основе нейросетевых алгоритмов // Образовательные технологии и общество. – 2020. Т. 23. № 1. С. 73-83.
5. Хизгияев В.И., Петров М.Н. Использование современных методов машинного обучения для мониторинга состояния: обзор теории, приложений и последних достижений // Экспертные системы с приложениями. 2023. Vol. 213. С. 118-905.
6. Шарма Дж.К., Шарма С. Применение моделей искусственных нейронных сетей для мониторинга состояния промышленного вентилятора // International Journal of Intelligent Systems and Applications in Engineering. 2023. Vol. 11. № 10. pp. 574-590.
7. Chavez H., Chavez-Arias B., Contreras-Rosas S., Alvarez-Rodriguez J.M., Raymundo C. Artificial neural network model to predict student performance using nonpersonal information // Frontiers in education. 2023. Vol. 8.
8. Gharehbaghi K., McManus K. TIS condition monitoring using ANN integration: an overview // Journal of Engineering, Design and Technology. 2019. Vol. 17. № 1. pp. 204-217.
9. Li D., Liu J., Wu Z., Wang X. Recurrent neural network-based model for estimating the life condition of a dry gas pipeline // Journal of Loss Prevention in the Process Industries. 2023. Vol. 81. pp. 104-891.
10. Li D., Wu Z., Liu J. Прогнозирование остаточного ресурса трубопроводов с использованием рекуррентных нейронных сетей // Научно-технический вестник ОАО «НК «Роснефть». 2022. № 2. С. 78-85.
11. Li M., Wang X., Wang Y., Chen Y., Chen Y. Study-GNN: A Novel Pipeline for Student Performance Prediction Based on Multi-Topology Graph Neural Networks // Sustainability. 2022. Vol. 14. № 13. pp. 65-79.
12. Momeni A., Gupta T., Salehi S. Prediction of water pipeline condition parameters using artificial neural networks // Journal of pipeline systems engineering and practice. 2022. Vol. 13. № 4. pp. 203-402.
13. Siyam N., Alqaryouti O., Abdallah S. Machine learning approaches for prediction and classification of pipeline failures: A systematic literature review // Applied sciences. 2020. Vol. 10. № 14. pp. 37-49.
14. Wang L., Xu Y., Shi B. 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. № 4. pp. 367-378.

15. Zhang T., Bai H., Sun S. Intelligent natural gas and hydrogen pipeline dispatching using the coupled thermodynamics-informed neural network and compressor boolean neural network // Processes. 2022. Vol. 10. № 2.

Implementation of neural network algorithms in courses for forecasting the technical condition of pipeline systems

Adelina R. Khamidullina

Expert specialist

Ufa State Petroleum Technological University

Ufa, Russia

hamidullina_aa@mail.ru

ORCID 0000-0000-0000-0000

Yulia K. Shchelokova

Expert specialist

Ufa State Petroleum Technological University

Ufa, Russia

Juliashchel.90@mail.ru

ORCID 0000-0000-0000-0000

Received 04.02.2025

Accepted 25.03.2025

Published 30.04.2025

UDC 004.42(075.8)+621.381.7

DOI 10.25726/y9159-2129-6794-n

EDN RMSYCM

VAK 5.8.7. Methodology and technology of vocational education (pedagogical sciences)

OECD 05.03.HE. EDUCATION, SPECIAL

Abstract

The present study is devoted to studying the potential of introducing neural network algorithms into educational programs for training specialists in the field of forecasting the technical condition of pipeline systems. Pipeline systems are critical infrastructure facilities that require constant monitoring and maintenance. Traditional teaching methods do not allow us to fully develop the competencies necessary to work with modern intelligent monitoring systems. The study developed and tested an integrated educational module based on neural network technologies, which includes theoretical and practical components. The results of the experimental introduction into the educational process showed a significant increase in the level of professional competencies among students in the experimental group compared with the control group: the average score in specialized disciplines increased by 18.7%, and the ability to solve complex diagnostic problems increased by 23.4%. The analysis of feedback data from students and teachers indicates increased motivation to learn and a deeper understanding of the subject area. The proposed model for integrating neural network algorithms into the educational process can be scaled for various technical disciplines and levels of education, taking into account the specifics of the subject areas.

Keywords

neural network algorithms, educational technologies, pipeline systems, forecasting of technical condition, monitoring, artificial intelligence, professional competencies.

References

1. Zemenkova M.Y. Intelligent monitoring of the condition of pipeline transportation facilities for hydrocarbons using neural network technologies // Notes of the Mining Institute. 2022. Vol. 105. pp. 115-123.
2. Korneev A.M., Sukhanov A.V., Shipulin I.A. Introduction of artificial intelligence technologies in engineering education: problems and prospects // Tomsk State University bulletin. 2021. № 465. pp. 174-180.
3. Meshcheryakov V.A., Migranov L.O., Chigvintsev S.V. Assessment of the condition of pipelines using convolutional neural networks // Energy. 2020. Vol. 13. No. 3. p. 618.
4. Morozova N.S., Petrov A.A. Adaptive learning systems based on neural network algorithms // Educational technologies and society. 2020. Vol. 23. № 1. pp. 73-83.
5. Khizgiyaev V.I., Petrov M.N. The use of modern machine learning methods for health monitoring: a review of theory, applications and recent achievements // Expert systems with applications. 2023. Vol. 213. C. 118-905.
6. Sharma J.K., Sharma S. Application of artificial neural network models for monitoring the state of an industrial fan // International journal of intelligent systems and applications in engineering. 2023. Vol. 11. № 10. pp. 574-590.
7. Chavez H., Chavez-Arias B., Contreras-Rosas S., Alvarez-Rodriguez J.M., Raymundo C. Artificial neural network model to predict student performance using nonpersonal information // Frontiers in education. 2023. Vol. 8.
8. Gharehbaghi K., McManus K. TIS condition monitoring using ANN integration: an overview // Journal of Engineering, Design and Technology. 2019. Vol. 17. № 1. pp. 204-217.
9. Li D., Liu J., Wu Z., Wang X. Recurrent neural network-based model for estimating the life condition of a dry gas pipeline // Journal of Loss Prevention in the Process Industries. 2023. Vol. 81. pp. 104-891.
10. Li D., Wu Z., Liu J. Прогнозирование остаточного ресурса трубопроводов с использованием рекуррентных нейронных сетей // Научно-технический вестник ОАО «НК «Роснефть». 2022. № 2. С. 78-85.
11. Li M., Wang X., Wang Y., Chen Y., Chen Y. Study-GNN: A Novel Pipeline for Student Performance Prediction Based on Multi-Topology Graph Neural Networks // Sustainability. 2022. Vol. 14. № 13. pp. 65-79.
12. Momeni A., Gupta T., Salehi S. Prediction of water pipeline condition parameters using artificial neural networks // Journal of pipeline systems engineering and practice. 2022. Vol. 13. № 4. pp. 203-402.
13. Siyam N., Alqaryouti O., Abdallah S. Machine learning approaches for prediction and classification of pipeline failures: A systematic literature review // Applied sciences. 2020. Vol. 10. № 14. pp. 37-49.
14. Wang L., Xu Y., Shi B. 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. № 4. pp. 367-378.
15. Zhang T., Bai H., Sun S. Intelligent natural gas and hydrogen pipeline dispatching using the coupled thermodynamics-informed neural network and compressor boolean neural network // Processes. 2022. Vol. 10. № 2.