

Роль искусственного интеллекта в предотвращении утечек воды из сетей водоснабжения

Виктор Иванович Баженов¹, Олег Григорьевич Примин^{2,3},
Владимир Викторович Баженов⁴

¹ АО «Водоснабжение и водоотведение» (АО «ВИВ»); г. Москва, Россия;

² Научно-исследовательский институт строительной физики Российской академии архитектуры и строительных наук (НИИСФ РААСН); г. Москва, Россия;

³ Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ); г. Москва, Россия;

⁴ Московский государственный технический университет имени Н.Э. Баумана (национальный исследовательский университет) (МГТУ им. Н.Э. Баумана); г. Москва, Россия

АННОТАЦИЯ

Введение. Одной из основ устойчивого развития и совершенствования централизованных систем водоснабжения (ЦСВ) и водоотведения является использование средств искусственного интеллекта (ИИ) на основе алгоритмов и моделей машинного обучения (МО): контролируемого, неконтролируемого, обучения с подкреплением. Утечки и несанкционированные подключения к ЦСВ представляют собой риски, приводя к потерям питьевой воды и снижению ценообразования в области учета водного ресурса. Актуальность связана с решением практических задач ИИ на основе новейших инноваций — прогнозированием и предотвращением аварий на ЦСВ при оптимальном планировании ремонтных работ и своевременном техническом обслуживании. Цель исследования — обосновать роль ИИ, использующего средства МО, в задачах прогнозирования отказов трубопроводов и аварийных ситуаций в ЦСВ.

Материалы и методы. Изучение информации о роли ИИ в предотвращении утечек воды из сетей водоснабжения выполнено методом литературного обзора примененных алгоритмов МО на предмет прогнозирования отказов труб в ЦСВ.

Результаты. Выявлены и представлены модели МО, используемые для диагностического анализа с целью прогнозирования утечек воды из сетей водоснабжения. Обзор технологий свидетельствует об использовании 18 алгоритмов МО для решения задач, связанных с утечками ЦСВ. Начало применения нейросетевых алгоритмов Кохонена (KNN) в России говорит о наличии единственного переведенного на русский язык нейросетевого ПО STATISTICA Automated Neural Networks. Начинают активно развиваться акустические и ультразвуковые методы мониторинга состояния подземных трубопроводных сетей, основанные на распространении объемных и направленных волн (шума).

Выводы. Водоканалам необходимо выполнять надежный и непрерывный сбор данных, что помогает принимать лучшие и надежные решения. Базы данных могут включать: диаметр трубы, длину участка и возраст трубы, давление, тип грунта. Собственно давление (или перепад) в сети не является признаком аварийности. Данный параметр следует рассматривать совместно с количеством отказов сети (аварий) на участках.

КЛЮЧЕВЫЕ СЛОВА: искусственный интеллект, машинное обучение, сети водоснабжения, водораспределительная сеть, прогнозирование отказов трубопроводов, управление данными

ДЛЯ ЦИТИРОВАНИЯ: Баженов В.И., Примин О.Г., Баженов В.В. Роль искусственного интеллекта в предотвращении утечек воды из сетей водоснабжения // Строительство: наука и образование. 2024. Т. 14. Вып. 4. Ст. 98–111. URL: <http://nso-journal.ru>. DOI: 10.22227/2305-5502.2024.4.98-111

Автор, ответственный за переписку: Виктор Иванович Баженов, bazhenov@pump.ru.

The role of artificial intelligence in preventing water leakages from water supply networks

Victor I. Bazhenov¹, Oleg G. Primin^{2,3}, Vladimir V. Bazhenov⁴

¹ JSC “Water and Wastewater”; Moscow, Russian Federation;

² Research Institute of Building Physics of the Russian Academy of Architecture and Construction Sciences; Moscow, Russian Federation;

³ Moscow State University of Civil Engineering (National Research University) (MGSU); Moscow, Russian Federation;

⁴ Bauman Moscow State Technical University (BMSTU); Moscow, Russian Federation

ABSTRACT

Introduction. One of foundations for the sustainable development and improvement of centralized water supply networks (CWN) and sanitation is the use of artificial intelligence (AI) based on machine learning (ML) algorithms and models: supervised, unsupervised, reinforcement learning. Leaks and unauthorized connections to CWN pose risks, leading to losses of drinking water and reduced pricing in the field of water resource metering. The relevance is associated with solving practical AI problems based on the latest innovations — forecasting and preventing accidents at CWN with optimal planning of repair work and timely maintenance. The purpose of study is to substantiate the role of AI using ML tools in the tasks of predicting pipeline failures and emergency situations in CWN.

Materials and methods. The study of information on the role of AI in preventing water leaks from water supply networks was carried out using the method of literature review of the used AI algorithms for predicting pipe failures in CWN.

Results. The ML models used for diagnostic analysis to predict water leaks from CWN are identified and presented. The review of technologies shows the use of 18 ML algorithms to solve problems related to leaks in CWN. Start of use of Kohonen neural network algorithms (KNN) in Russia indicates the availability of the only neural network software translated into Russian, STATISTICA Automated Neural Networks. Acoustic and ultrasonic methods for monitoring the condition of underground pipeline networks, based on the propagation of volumetric and directional waves (noise), are beginning to develop rapidly.

Conclusions. Among the conclusions — for the Sustainable Development of CWN, water utilities need to ensure reliable and continuous data collection, this is a key practice that will help make reliable decisions based on AI predictions after the ML phase. Databases may include: pipe diameter, length of the section and age of the pipe, pressure, type of soil. The pressure itself (or difference) in the network is not a sign of an accident. This parameter should be considered together with the number of network failures (accidents) in the sections.

KEYWORDS: artificial intelligence, machine learning, water supply networks, water distribution networks, pipeline failure prediction, data management

FOR CITATION: Bazhenov V.I., Primin O.G., Bazhenov V.V. The role of artificial intelligence in preventing water leakages from water supply networks. *Stroitel'stvo: nauka i obrazovanie* [Construction: Science and Education]. 2024; 14(4):98-111. URL: <http://nso-journal.ru>. DOI: 10.22227/2305-5502.2024.4.98-111

Corresponding author: Victor I. Bazhenov, bazhenov@pump.ru.

ВВЕДЕНИЕ

Одной из основ устойчивого развития и совершенствования централизованных систем водоснабжения (ЦСВ) и водоотведения является использование средств искусственного интеллекта (ИИ), а именно алгоритмов и моделей машинного обучения (МО) (контролируемого, неконтролируемого, обучения с подкреплением). Утечки и несанкционированные подключения к централизованным системам водоснабжения представляют собой серьезный риск, поскольку они приводят к потерям питьевой воды и снижают ценообразование в области учета данного водного ресурса.

Чистая питьевая вода — дефицитный ресурс во многих регионах. Обнаружение утечек и/или их локализация — сложная задача из-за комплексной динамики сетей распределения воды. Вследствие комплексной динамики сети и меняющихся моделей спроса обнаружение как малых, так и больших утечек — тяжелая гидравлическая задача. Однако бурно развивающиеся средства ИИ служат потенциалом для решения этой технической задачи на основе алгоритмов МО. Потенциал свидетельствует о недостаточности систематических исследований по анализу роли ИИ в достижении целей устойчивого развития (Sustainable Development Goals — набор из 17 руководящих задач, принятых ООН, каждая из которых фокусируется на аспекте человеческого развития и устойчивости экосистем).

Актуальность связана с решением практических задач ИИ на базе новейших инновационных направлений — прогнозированием и предотвращением аварий на водораспределительных сетях при опти-

мальном планировании ремонтных работ и своевременном техническом обслуживании. Профилактическое обслуживание и обнаружение утечек с помощью ИИ повышает эффективность управления инфраструктурой водоснабжения. Данная эффективность связана с применением алгоритмов МО для улучшения процесса принятия решений и совершенствования стратегий управления водными ресурсами. Обзор практик важен, поскольку содержит анализ алгоритмов МО, практику использования выходных переменных МО, многофакторный анализ разрушения трубопроводов водоснабжения.

Интеллектуальные системы на основе средств ИИ, как правило, используют информационно-коммуникационные технологии (ИКТ), которые достигают целей эффективности и устойчивости в городском управлении водными ресурсами. ИКТ применяет сложную архитектуру, включающую датчики, связь, программируемые логические контроллеры (ПЛК), исполнительные механизмы, удаленные терминальные устройства, серверы данных и управления, называемые системой диспетчерского управления и сбора данных (SCADA). Преобразование централизованных сетей водоснабжения в киберфизические системы с помощью SCADA поддерживает мониторинг в реальном времени, сбор данных и удаленное управление для повышения эффективности работы системы и расширения ее возможностей, связанных с быстрым и точным обнаружением сбоев и своевременными действиями по восстановлению. Это, в свою очередь, повышает устойчивость системы в целом.

Цель исследования — обосновать роль искусственного интеллекта, использующего средства ма-

шинного обучения, в задачах прогнозирования отказов трубопроводов и аварийных ситуаций в водораспределительных сетях.

МАТЕРИАЛЫ И МЕТОДЫ

ГОСТ Р 59277–2020 закрепляет за ИИ комплекс технологических решений, позволяющий имитировать когнитивные функции человека и получение результатов, сопоставимых как минимум с результатами интеллектуальной деятельности человека. ГОСТ Р 59895–2021 трактует МО как процесс автоматического обучения и совершенствования поведения системы ИИ на базе обработки массива обучающих данных без явного программирования.

Изучение информации о роли ИИ в предотвращении утечек воды из сетей водоснабжения выполнено методом литературного обзора использованных моделей (алгоритмов) МО на предмет прогнозирования отказов труб в сетях водоснабжения.

Задействован тип ИИ, основанный на предиктивной аналитике, использующей алгоритмы МО для анализа данных и прогнозирования будущих событий или тенденций. Предиктивная аналитика применяется для прогнозирования моделей водопользования:

- тенденций использования МО в управлении сетями водоснабжения;

- мониторинга водных ресурсов в режиме реального времени;
- прогнозирования доступности воды, оптимизации распределения и улучшения обслуживания инфраструктуры.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Результаты исследования показывают, что многие из проанализированных работ ссылаются на факторы, влияющие на разрушение трубопроводов, например:

- внутренние (год установки труб, их длина и материал, диаметр, антикоррозионная защита);
- эксплуатационные (история и тип аварий, давление или скорость в трубопроводе);
- внешние (транспортная нагрузка, коррозионная активность почвы, температура).

Выявлены и представлены модели МО, используемые для диагностического анализа с целью прогнозирования утечек воды из сетей водоснабжения (табл. 1). Основу классификатора моделей составила работа [1] при внесении изменений.

Обзор технологий свидетельствует об использовании 18 алгоритмов МО для решения задач (табл. 2), связанных с утечками систем водоснабжения. Это, конечно, не полный список алгоритмов, в особенности

Табл. 1. Модели и алгоритмы машинного обучения, использованные для предотвращения утечек воды из сетей водоснабжения

Модели и алгоритмы МО	Описание
NB Наивно-Байесовская (Naive Bayesian)	Основана на правиле Байеса и разделяет данные на различные классы с помощью входных переменных или атрибутов. Предполагается, что переменные условно независимы, а их возможные взаимодействия игнорируются
BBN Байесовские сети доверия (Bayesian Belief Networks)	Более сложная модель, основанная на вероятности Байеса. Графически их приводят в виде прямых ациклических графов, где узлы представляют параметры, а дуги — вероятностные отношения между ними
LR Линейная регрессия (Linear regression)	Представляет собой статистическую процедуру, помогающую прогнозировать
FL Нечеткая логика (Fuzzy logic)	Сочетание классической логики и теории множеств, использующей понятие нечеткого множества (расширение булевой логики посредством операндов 0 и 1). Так, метод FL с учетом неопределенности может помочь отличить многофакторные оценки риска отказа трубопроводов: факторы аварий (возраст трубы, материал, частота аварий) от факторов последствий (ущерб, нарушение бизнеса и прочее)
GLM Обобщенные линейные модели (Generalized Linear Models)	Включает линейную регрессию, модели дисперсионного анализа, логит и пробит модели (для бинарных ответов), логлинейные модели и мультиномиальные модели ответов для подсчетов
SM Модели выживания (Survival Models)	В модели зависимой переменной (или ответом) является время ожидания до наступления интересующего события. Это позволяет рассматривать отказы труб с течением времени
GT Теория графов (Graph Theory)	Область дискретной математики, изучающей графы, геометрический подход к изучению объектов и связей между ними. Объекты называются вершинами графа, связи между парами объектов — ребрами. При описании взаимосвязи пар различных объектов обычно имеют дело с графом. Например, в схеме городского водоснабжения вершинами графа являются точки водоразбора, а ребрами — трубопроводы, соединяющие эти точки. Используют для решения оптимизационных задач
SVR Регрессия опорных векторов (Support Vector Regression)	В модели объясняющие переменные отображаются с помощью нелинейных структур в пространство высокой размерности, затем в этом пространстве выполняется линейная регрессия. Выходная переменная, прогнозируемая SVR, является непрерывной, в данном случае это частота отказов совокупности труб

Окончание табл. 1

Модели и алгоритмы МО	Описание
GP (иногда GA) Генетическое программирование (Genetic Programming или Genetic Algorithm)	Автоматическое создание или изменение программ с помощью генетических алгоритмов, развитие парадигмы эволюционного программирования. В древовидном кодировании каждый узел дерева содержит примитивную функцию (например, сумма, остаток, произведение), а каждый лист — объясняемая переменная
EPR Эволюционная полиномиальная регрессия (Evolutionary Polynomial Regression)	Гибридная техника управления данными, относящаяся к семейству стратегий GP. Объединяет в себе мощные регрессионные возможности обычных методов численной регрессии и превосходную способность генетического программирования к поиску решений
AHP Метод анализа иерархий (Analytical Hierarchy Process)	Структурированная техника принятия комплексных решений, где в традиционной формулировке суждения экспертов представляются в виде точных чисел (пропорций) для формирования матрицы сравнения критериев и альтернатив
RM Модель ранжирования (Ranking Model)	Простые модели, которые ранжируют трубы по определенной переменной или комбинации переменных и другие алгоритмы повышения рангов, которые итеративно обновляют выходные переменные набора данных в поисках улучшения определенной метрики качества
DT Деревья принятия решений (Decision Trees)	Модели, позволяющие решать задачи классификации, иерархии и регрессии. DT используют для интеллектуального анализа данных (прогноз значения целевой переменной на основе нескольких переменных на входе)
RF Случайный лес (Random Forest)	Алгоритм коллективного обучения, который состоит из нескольких деревьев решений, где каждое дерево решений обучается независимо на случайном подмножестве данных. За счет большого количества деревьев результат улучшается
SVM Опорные векторные машины (Support Vector Machine)	Линейный алгоритм, используемый в задачах классификации и регрессионного анализа. Алгоритм создает линию или гиперплоскость, которая разделяет данные на классы
GNN Графовая нейронная сеть (Graph Neural Network)	Тип нейронной сети, базирующейся на теории графов, — напрямую работающая со структурой графа (структура данных, состоящая из двух компонентов: узлы — объекты, а ребра — связи между ними). Типичным применением GNN является классификация узлов. Может использоваться, например, для интеграции гидравлических и топологических характеристик сети водоснабжения
ANFIS Адаптивная нейро-нечеткая сеть (Adaptive neuro-fuzzy network)	Представляет собой разновидность искусственной нейронной сети, основанной на системе нечеткого вывода Такаги – Сугено. Данная система интегрирует принципы искусственных нейронных сетей (ИНС) с принципами нечеткой логики (гибридная система). ANFIS является универсальным оценщиком на основе наблюдаемых данных: правило — оценщик, а результат — оценка
KNN Нейронная сеть Кохонена (Kohonen Neural Networks)	Нейросеть настраивается с использованием алгоритма обучения (методом последовательных приближений) без контроля, поэтому ее также называют самоорганизующейся картой. Используется в основном для классификации, сжатия, распознавания образов и диагностики. KNN, в отличие от многослойной нейронной сети, очень проста; она представляет собой два слоя: входной и выходной. Подстраивается не под эталонное значение выхода, а под закономерности во входных данных

ИНС, которые бурно развиваются в настоящее время. В едином исследовании могут применяться различные модели и алгоритмы с/без использования ИНС. Изучение методов МО и их применения в данной теме показывает, что проблема может быть смоделирована по-разному. Это проявляется в различных выходных переменных, которые были использованы (время до отказа, индекс риска на участок, вероятность отказа, локализация уязвимых участков, интенсивность отказов и т.д.). Реализация методов обработки, таких как стратегии выборки или преобразования переменных, также сочетается с наиболее перспективными моделями (ИНС, KNN, LR, GP, SVR и далее) (табл. 2).

Наблюдаются следующие закономерности:

- тенденция к увеличению числа отказов одних и тех же труб в течение ряда лет подряд, что под-

тверждается положительной корреляцией между количеством предыдущих отказов трубы и выходной переменной. Водоканалам следует пересмотреть свои рекомендации по техническому обслуживанию и поискать возможные уязвимые места;

- согласно анализу годовой интенсивности отказов на километр, трубы меньшего диаметра, а также старые трубы имеют значительно более высокий уровень отказов;

- интенсивность отказов бетонных труб составляет около 0,65 отказов/км·год, что свидетельствует о серьезной проблеме, связанной с этим материалом.

Для устойчивого развития ЦСВ водоканалам требуется обеспечить надежный и непрерывный сбор данных — это важнейшая практика, которая поможет принимать надежные решения не только в настоящем,

Табл. 2. Модели прогноза и выходные переменные некоторых исследований — прогнозирование аварий трубопроводов в сетях водоснабжения

Модель	Выходная переменная и ссылка
BBN, SVR	Вероятность отказа [2]
FL	Индекс риска отказа при учете материала, возраста, длины и диаметра труб [3]
GP	Время до отказа трубопровода [4, 5]
GA	Локализация и размер утечек [6, 7]
RM, LR, NB, SM	Количество отказов трубопроводов [8]
RM	Индекс риска [9]
BBN	Количество повреждений труб [10]
SVR, CL, FL (ИНС)	Интенсивность отказов [11]
GT, SVM (ИНС)	Локализация утечек [12]
SVM, RF	Локализация утечек и снижение избыточного давления [13]
FL, АНР	Состояние труб [14]
EPR	Количество отказов трубопроводов [15]
LR	Время до отказа трубопровода [16]
RM, LR, SVM (ИНС)	Вероятность отказа [17]
DT, SM, RM	Время до отказа трубопровода [18]
DT, BBN (ИНС)	Вероятность отказа [19]
GLM, DT (ИНС)	Время до отказа трубопровода [20]
BBN	Вероятность отказа [21]
GNN (ИНС)	Локализация уязвимых участков по давлению [22, 23]
FL, ANFIS (ИНС)	Оставшийся срок службы труб [24]
FL, ANFIS (ИНС)	Локализация уязвимых участков [25–27]
FL, ANFIS (ИНС)	Частота отказов от диаметра и материалов труб [28]
DT	Время до отказа трубопровода [29]
RF	Локализация уязвимых участков [30–32]
CVM, RF (ИНС)	Дифференциация и идентификация событий сбоя [33]
KNN алгоритм Кохонена (ИНС)	Интенсивность отказов, вероятность безотказной работы, коэффициент готовности [34, 35]

но и в перспективе. Исследования отмечают рост и повышение достоверности информации об отказах трубопроводов при использовании SCADA систем на основе географических информационных систем (ГИС). Целью водоканала должно стать осознание ценности данных, а не экономия на источниках и времени для разработки надежной и качественной политики сбора сведений. Наиболее простыми факторами, которые водоканалы могут собирать в свои базы данных, являются, например: диаметр трубы, длина участка, возраст труб, давление, тип грунта. Собственно давление (или перепад) в сети, на наш взгляд, не является признаком аварийности. Это, несомненно, важный параметр, но его следует рассматривать совместно с количеством отказов сети (аварий) на участках.

Начало использования нейросетевых алгоритмов Кохонена (KNN) в России [34, 35], а также исследования, реализующие заключение о правильности проектирования и эксплуатации системы [36], неслучайны. Это свидетельствует о наличии единственного переведенного на русский язык нейросетевого ПО STATISTICA Automated Neural Networks (вендор

StatSoft Russia)¹, содержит самые современные нейросетевые алгоритмы обучения (метод сопряженных градиентов, алгоритм Левенберга – Марквардта, BFGS, алгоритм Кохонена). ПО предназначено для анализа данных, визуализации, прогнозирования и проведения статистических анализов, что позволяет взять его на вооружение при прогнозировании отказов труб в сетях водоснабжения.

Сеть Кохонена, в отличие от многослойной ИНС, очень проста; она представляет собой два слоя: входной и выходной. МО по правилу Кохонена относится к соревновательным методам обучения. В слое нейронной сети изменяются веса только одного нейрона-победителя, его веса признаются наиболее близкими к значениям входного сигнала. Сеть Кохонена обучается методом последовательных приближений. В процессе МО на входы подаются данные, но нейросеть при этом подстраивается не под эталонное значение выхода, а под закономерности во вход-

¹ STATISTICA Automated Neural Networks. URL: <https://лицензионныйсофт.рф/catalog/view/405/?ysclid=lwqkdt5dum161804109>

ных данных. Нейронная сеть Кохонена настраивается с использованием алгоритма обучения без контроля (поэтому ее называют самоорганизующейся картой) и используется в основном для классификации, сжатия, распознавания образов и диагностики.

Кроме вышеописанных способов, начинают активно развиваться акустические и ультразвуковые методы мониторинга состояния подземных трубопроводных сетей, основанные на распространении объемных и направленных волн (шума). А именно измерения вибрации и оценки спектральных характеристик шума утечки с помощью акселерометров, гидрофонов, волоконно-оптических датчиков и ультразвуковых (выше 20 кГц) методов [37–40]. Хотя эти методы применялись к трубам вручную, они подходят для использования в сочетании с автономными инспекционными роботами для обнаружения возникновения дефектов внутри труб. Исследуются соответствующие методы МО для прогноза местоположений утечек, основанные на подобных данных:

- генеративная состязательная сеть (Generative Adversarial Network — GAN) на основе новаторского подхода к МО, который сочетает теорию игр, вероятностное моделирование и теорию информации [38]. GAN состоит из двух нейронных сетей, генератора и дискриминатора, которые обучаются состязательным образом для генерации реалистичных данных;
- алгоритмы регрессионного МО на основе k -ближайших соседей (k -NN) и машины опорных векторов (SVM) [39];
- модели обнаружения утечек методом опорных векторов (SVM), искусственной нейронной сетью и глубоким обучением (Deep Learning — DL) проде-

монстрировали в основном стабильную производительность и высокую точность [40].

ЗАКЛЮЧЕНИЕ

Для устойчивого развития ЦСВ водоканалам требуется обеспечить надежный и непрерывный сбор данных — это важнейшая практика, которая поможет принимать надежные решения на основе прогнозов ИИ после фазы МО. Наиболее простыми факторами, которые водоканалы могут собирать в свои базы данных, являются, например: диаметр трубы, длина участка, возраст труб, давление, тип грунта. Собственно давление (или перепад) в сети, на наш взгляд, не служит признаком аварийности. Это, несомненно, важный параметр, но его следует рассматривать совместно с количеством отказов сети (аварий) на участках.

Тенденции и использование МО в управлении сетями водоснабжения выявили использование 18 алгоритмов для решения задач, связанных с утечками систем водоснабжения. Выходными переменными могут быть: интенсивность отказов, вероятность отказа, индекс риска, время до отказа, количество отказов, состояние труб, локализация уязвимых участков, оставшийся срок службы труб, вероятность безотказной работы, коэффициент готовности. Начало использования нейросетевых алгоритмов Кохонена в России связано с наличием русскоязычного программного обеспечения STATISTICA Automated Neural Networks.

Представлены сведения о развивающихся акустических и ультразвуковых методах мониторинга состояния подземных трубопроводных сетей, основанных на распространении объемных и направленных волн (шума), и соответствующие методы МО.

СПИСОК ИСТОЧНИКОВ

1. Robles-Velasco A. A machine learning approach to predict pipe failures in water distribution networks. 2022. 151 p. URL: <https://idus.us.es/handle/11441/131484>
2. Weeraddana D., Hapuarachchi H., Kumaraperuma L., Khoa N.L.D., Cai C. Long-term water pipe condition assessment: a semiparametric model using gaussian process and survival analysis // *Lecture Notes in Computer Science*. 2020. Pp. 487–499. DOI: 10.1007/978-3-030-47436-2_37
3. Pouri Z., Heidarimozaffar M. Spatial analysis and failure management in water distribution networks using fuzzy inference system // *Water Resources Management*. 2022. Vol. 36. Issue 6. Pp. 1783–1797. DOI: 10.1007/s11269-022-03104-5
4. Sattar A.M.A., Gharabaghi B., McBean E.A. Prediction of timing of watermain failure using gene expression models // *Water Resources Management*. 2016. Vol. 30. Issue 5. Pp. 1635–1651. DOI: 10.1007/s11269-016-1241-x
5. Sangroula U., Han K.H., Koo K.M., Gnawali K., Yum K.T. Optimization of water distribution networks using genetic algorithm based SOP-WDN program // *Water*. 2022. Vol. 14. Issue 6. P. 851. DOI: 10.3390/w14060851
6. Примин О.Г., Громов Г.Н. Совершенствование гидравлических расчетов систем водоснабжения с использованием электронных моделей // *International Journal for Computational Civil and Structural Engineering*. 2018. Т. 14. № 2. С. 141–148. DOI: 10.22337/2587-9618-2018-14-2-141-148. EDN OYBKZZ.
7. Примин О.Г., Громов Г.Н., Тен А.Э. Алгоритмы построения и калибровки электронных моделей системы водоснабжения // *Вестник МГСУ*. 2018. Т. 13. № 7 (118). С. 847–854. DOI: 10.22227/1997-0935.2018.7.847-854
8. Kleiner Y., Rajani B. Comparison of four models to rank failure likelihood of individual pipes // *Journal of Hydroinformatics*. 2012. Vol. 14. Issue 3. Pp. 659–681. DOI: 10.2166/hydro.2011.029

9. Wang R., Dong W., Wang Y., Tang K., Yao X. Pipe failure prediction: A data mining method // 2013 IEEE 29th International Conference on Data Engineering (ICDE). 2013. Pp. 1208–1218. DOI: 10.1109/ICDE.2013.6544910
10. Francis R.A., Guikema S.D., Henneman L. Bayesian belief networks for predicting drinking water distribution system pipe breaks // Reliability Engineering & System Safety. 2014. Vol. 130. Pp. 1–11. DOI: 10.1016/j.res.2014.04.024
11. Aydogdu M., Firat M. Estimation of failure rate in water distribution network using fuzzy clustering and LS-SVM methods // Water Resources Management. 2015. Vol. 29. Issue 5. Pp. 1575–1590. DOI: 10.1007/s11269-014-0895-5
12. Komba G.M., Mathonsi T.E., Owolawi P.A. Water pipeline leak detection and localisation in water distribution networks // 2023 International Conference on Emerging Trends in Networks and Computer Communications (ETNCC). 2023. Pp. 140–145. DOI: 10.1109/ETNCC59188.2023.10284934
13. Komba G.M., Mathonsi T.E., Owolawi P.A. Optimizing leak detection and location in water distribution networks using SVM-RF algorithm // 2024 15th International Conference on Mechanical and Intelligent Manufacturing Technologies (ICMIMT). 2024. Pp. 27–33. DOI: 10.1109/ICMIMT61937.2024.10585935
14. Amaitik N.M., Buckingham C.D. Developing a hierarchical fuzzy rule-based model with weighted linguistic rules: A case study of water pipes condition prediction // 2017 Computing Conference. 2017. Pp. 30–40. DOI: 10.1109/SAI.2017.8252078
15. Farmani R., Kakoudakis K., Behzadian K., Butler D. Pipe failure prediction in water distribution systems considering static and dynamic factors // Procedia Engineering. 2017. Vol. 186. Pp. 117–126. DOI: 10.1016/j.proeng.2017.03.217
16. Rifaai T.M., Abokifa A.A., Sela L. Integrated approach for pipe failure prediction and condition scoring in water infrastructure systems // Reliability Engineering & System Safety. 2022. Vol. 220. P. 108271. DOI: 10.1016/j.res.2021.108271
17. Fan X., Wang X., Zhang X., Yu X. Machine learning based water pipe failure prediction: The effects of engineering, geology, climate and socio-economic factors // Reliability Engineering & System Safety. 2022. Vol. 219. P. 108185. DOI: 10.1016/j.res.2021.108185
18. Snider B., McBean E.A. Watermain breaks and data: The intricate relationship between data availability and accuracy of predictions // Urban Water Journal. 2020. Vol. 17. Issue 2. Pp. 163–176. DOI: 10.1080/1573062X.2020.1748664
19. Giraldo-González M.M., Rodríguez J.P. Comparison of statistical and machine learning models for pipe failure modeling in water distribution networks // Water. 2020. Vol. 12. Issue 4. P. 1153. DOI: 10.3390/w12041153
20. Almheiri Z., Meguid M., Zayed T. Intelligent approaches for predicting failure of water mains // Journal of Pipeline Systems Engineering and Practice. 2020. Vol. 11. Issue 4. DOI: 10.1061/(ASCE)PS.1949-1204.0000485
21. Tang K., Parsons D.J., Jude S. Comparison of automatic and guided learning for Bayesian networks to analyse pipe failures in the water distribution system // Reliability Engineering & System Safety. 2019. Vol. 186. Pp. 24–36. DOI: 10.1016/j.res.2019.02.001
22. Shekofteh M., Jalili Ghazizadeh M., Yazdi J. A methodology for leak detection in water distribution networks using graph theory and artificial neural network // Urban Water Journal. 2020. Vol. 17. Issue 6. Pp. 525–533. DOI: 10.1080/1573062X.2020.1797832
23. Peng S., Cheng J., Wu X., Fang X., Wu Q. Pressure sensor placement in water supply network based on graph neural network clustering method // Water. 2022. Vol. 14. Issue 2. P. 150. DOI: 10.3390/w14020150
24. Tavakoli R., Sharifara A., Najafi M. Artificial neural networks and adaptive neuro-fuzzy models to predict remaining useful life of water pipelines // World Environmental and Water Resources Congress 2020. 2020. Pp. 191–204. DOI: 10.1061/9780784482988.019
25. Romanov R.V., Kochetkova S.S. Application of a neural network approach for localization of problem areas of a centralized water supply system // Third International Conference on Optics, Computer Applications, and Materials Science (CMSD-III 2023). 2024. P. 30. DOI: 10.1117/12.3025000
26. Mehran Jafari S., Bozorg-Haddad O., Reza Nikoo M. Application of artificial neural network and fuzzy logic in the urban water distribution networks pipe failure modeling // Studies in Computational Intelligence. 2022. Pp. 333–354. DOI: 10.1007/978-981-19-2519-1_16
27. Rashid A., Kumari S. Optimal design of water distribution network using Neuro – Fuzzy technique. 2021. DOI: 10.21203/rs.3.rs-915481/v1
28. Gheibi M., Moezzi R., Taghavian H., Wacławek S., Emrani N., Mohtasham M. et al. A risk-based soft sensor for failure rate monitoring in water distribution network via adaptive neuro-fuzzy interference systems // Scientific Reports. 2023. Vol. 13. Issue 1. DOI: 10.1038/s41598-023-38620-w
29. Yang Y., Hu Y., Zheng J. A decision tree approach to the risk evaluation of urban water distribution network pipes // Safety. 2020. Vol. 6. Issue 3. P. 36. DOI: 10.3390/safety6030036
30. Lučin I., Lučin B., Čarija Z., Sikirica A. Data-driven leak localization in urban water distribution networks using big data for random forest classifier // Mathematics. 2021. Vol. 9. Issue 6. P. 672. DOI: 10.3390/math9060672
31. Lucin I., Carija Z., Druzeta S., Lucin B. Detailed leak localization in water distribution networks using random forest classifier and pipe segmentation //

IEEE access. 2021. Vol. 9. Pp. 155113–155122. DOI: 10.1109/ACCESS.2021.3129703

32. Marvin G., Grbčić L., Družeta S., Kranjčević L. Water distribution network leak localization with histogram-based gradient boosting // Journal of Hydroinformatics. 2023. Vol. 25. Issue 3. Pp. 663–684. DOI: 10.2166/hydro.2023.102

33. Parajuli U., Shin S. Identifying failure types in cyber-physical water distribution networks using machine learning models // AQUA — Water Infrastructure, Ecosystems and Society. 2024. Vol. 73. Issue 3. Pp. 504–519. DOI: 10.2166/aqua.2024.264

34. Timashev S.A., Makeeva T.V. Assessment and prediction of water supply network reliability under information shortage using artificial neural networks // ASCE Inspire 2023. 2023. Pp. 733–741. DOI: 10.1061/9780784485163.085

35. Тимашев С.А., Макеева Т.В. Оценка надежности городской водопроводной сети при дефиците информации методом искусственных нейронных сетей. Екатеринбург : Издательство Уральского университета, 2023. 78 с.

36. Карамбиров С.Н., Уманский П.М. Кластерный анализ участков водопроводной сети // Природообустройство. 2016. № 1. С. 23–27. EDN VVWITX.

37. Scussel O., Brennan M.J., Almeida F.C., Muggleton J.M., Rustighi E., Joseph P.F. Estimating the spectrum of leak noise in buried plastic water distribution pipes using acoustic or vibration measurements remote from the leak // Mechanical Systems and Signal Processing. 2021. Vol. 147. P. 107059. DOI: 10.1016/j.ymssp.2020.107059

38. Liu R., Zayed T., Xiao R. Advanced acoustic leak detection in water distribution networks using integrated generative model // Water Research. 2024. Vol. 254. P. 121434. DOI: 10.1016/j.watres.2024.121434

39. Yussif A.M., Sadeghi H., Zayed T. Application of machine learning for leak localization in water supply networks // Buildings. 2023. Vol. 13. Issue 4. P. 849. DOI: 10.3390/buildings13040849

40. Fares A., Tijani I.A., Rui Z., Zayed T. Leak detection in real water distribution networks based on acoustic emission and machine learning // Environmental Technology. 2023. Vol. 44. Issue 25. Pp. 3850–3866. DOI: 10.1080/09593330.2022.2074320

Поступила в редакцию 4 сентября 2024 г.

Принята в доработанном виде 4 сентября 2024 г.

Одобрена для публикации 20 сентября 2024 г.

ОБ АВТОРАХ: **Виктор Иванович Баженов** — доктор технических наук, профессор, исполнительный директор; АО «Водоснабжение и водоотведение» (АО «ВИВ»); 115054, г. Москва, Большой Строченовский пер., д. 7; РИНЦ ID: 266644, Scopus: 57202817636, ORCID: 0000-0002-6619-1212; bazhenov@pump.ru;

Олег Григорьевич Примин — доктор технических наук, главный научный сотрудник; Научно-исследовательский институт строительной физики Российской академии архитектуры и строительных наук (НИИСФ РААСН); 127238, г. Москва, Локомотивный проезд, д. 21; профессор; Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ); 129337, г. Москва, Ярославское шоссе, д. 26; РИНЦ ID: 414862; tepper2007@yandex.ru;

Владимир Викторович Баженов — аспирант, лаборант; Московский государственный технический университет имени Н.Э. Баумана (национальный исследовательский университет) (МГТУ им. Н.Э. Баумана); 105005, г. Москва, 2-я Бауманская, д. 5; РИНЦ ID: 1228325; BazhenovVladimirV@gmail.com.

Вклад авторов:

Баженов В.И. — научное руководство, идея, написание исходного текста.

Примин О.Г. — сбор материала, обобщение материала, доработка текста.

Баженов В.В. — идентификация алгоритмов машинного обучения в исходной литературе, доработка текста.

Авторы заявляют об отсутствии конфликта интересов.

INTRODUCTION

One of the foundations for sustainable development and improvement of centralized water supply and sanitation systems is the use of artificial intelligence (AI), namely machine learning algorithms and models (supervised, unsupervised, reinforcement learning). Leaks and unauthorized connections to centralized water supply systems pose a serious risk, as they lead to losses of drinking water and reduce pricing in the field of accounting for this water resource.

Clean drinking water is a scarce resource in many regions. Detecting leaks and/or localizing them is challenging due to the complex dynamics of water distribution networks. Due to the complex network dynamics and changing demand patterns, detecting both small and large leaks is a complex hydraulic challenge. However, rapidly developing AI tools offer the potential to solve this technical challenge based on machine learning (ML) algorithms. The potential highlights the lack of systematic research to analyze the role of AI research in achiev-

ing the Sustainable Development Goals (SDG). SDG is the set of 17 guiding targets adopted by the UN, each of which focuses on an aspect of human development and ecosystem sustainability.

The relevance is related to solving practical AI problems based on the latest innovative trends — forecasting and preventing accidents in water distribution networks with optimal planning of repair research and timely maintenance. Preventive maintenance and leak detection using AI increases the efficiency of water supply infrastructure management. This efficiency is associated with the use of ML algorithms to improve the decision-making process and improve water resources management strategies. The review of practices is relevant because it contains an analysis of ML algorithms, the practice of using ML output variables, and a multivariate analysis of the destruction of water supply pipelines.

Intelligent systems based on AI tools generally use information and communication technologies (ICT), which have been achieved to achieve the goals of efficiency and sustainability in urban water management. ICT uses a complex architecture including sensors, communication, programmable logic controllers (PLC), actuators, remote terminal devices, data and control servers, called supervisory control and data acquisition (SCADA) system. Transforming centralized water supply networks into cyber-physical systems using SCADA supports real-time monitoring, data collection and remote control to improve the system’s performance and enhance its capabilities related to rapid and accurate fault detection and timely recovery actions. This, in turn, improves the resilience of the overall system.

The purpose of study is to substantiate the role of artificial intelligence using machine learning tools in the tasks of predicting pipeline failures and emergency situations in water distribution networks.

MATERIALS AND METHODS

Russian standard GOST R 59277–2020 assigns to artificial intelligence (AI) a set of technological solu-

tions that allow simulating human cognitive functions and obtaining results comparable, at a minimum, with the results of human intellectual activity. Russian standard GOST R 59895–2021 interprets machine learning (ML) as a process of automatic learning and improving the behavior of an AI system based on processing an array of training data without explicit programming.

The study of information on the role of artificial intelligence in preventing water leaks from water supply networks was carried out using the method of a literature review of the used models (algorithms) for predicting pipe failures in water supply networks.

The type of AI used is predictive analytics, which uses machine learning algorithms to analyze data and predict future events or trends. Predictive analytics is used to predict water use patterns:

- trends in the use of machine learning in water supply network management;
- monitoring of water resources in real time;
- forecasting water availability, optimizing distribution and improving infrastructure maintenance.

RESULTS OF THE STUDY

The results of the study show that many of the analyzed papers refer to factors that influence pipeline failure, such as:

- internal (year of pipe installation, their length and material, diameter, anti-corrosion protection);
- operational (history and type of accidents, pressure or velocity in the pipeline);
- external (transport load, soil corrosivity, temperature).

Models used for diagnostic analysis to predict water leaks from water supply networks are identified and presented (Table 1). The model classifier is based on the research [1], with modifications.

The review of technologies shows the use of 18 ML algorithms to solve problems (Table 2) related to water supply system leaks. This is, of course, not a complete list of algorithms, especially for artificial neural networks

Table 1. Machine learning (ML) models and algorithms used to prevent water leaks from water supply networks

ML models and algorithms	Description
NB Naive Bayesian	Based on Bayes’ rule, it separates data into different classes using input variables or attributes. It assumes that the variables are conditionally independent and their possible interactions are ignored
BBN Bayesian Belief Networks	A more complex model based on Bayesian probability. They are graphically represented as direct acyclic graphs, where nodes represent parameters and arcs represent probabilistic relationships between them
LR Linear regression	It is a statistical procedure that helps in forecasting
FL Fuzzy logic	Combination of classical logic and set theory using the concept of fuzzy set (extension of Boolean logic, by means of operands 0 and 1). Thus, the FL method taking into account uncertainty can help to evaluate multifactorial assessments of the risk of pipeline failure: accident factors (pipe age, material, accident frequency) from consequence factors (damage, business disruption, etc.)
GLM Generalized Linear Models	Includes linear regression, analysis of variance models, logit and probit models (for binary responses), loglinear models, and multinomial response models for counts

End of the Table 1

ML models and algorithms	Description
SM Survival Models	In the model, the dependent variable (or response) is the waiting time until the event of interest occurs. This allows pipe failures to be considered over time
GT Graph Theory	An area of discrete mathematics that studies graphs, a geometric approach to studying objects and the connections between them. Objects are called graph vertices, and connections between pairs of objects are called edges. When describing the relationship between pairs of different objects, one usually deals with a graph. For example, a city water supply scheme, where the graph vertices are water intake points, and the edges are the pipelines connecting these points. It is used to solve optimization problems
SVR Support Vector Regression	In the model, the explanatory variables are mapped using nonlinear structures into a high-dimensional space, and then linear regression is performed on that space. The output variable predicted by SVR is continuous, in this case the failure rate of the population of pipes
GP (sometimes GA) Genetic Programming (or Genetic Algorithm)	Automatic creation or modification of programs using genetic algorithms, development of the evolutionary programming paradigm. In tree — like coding, each tree node contains a primitive function (e.g., sum, remainder, product), and each leaf contains an explained variable
EPR Evolutionary Polynomial Regression	Hybrid data management technique belonging to the GP family of strategies. It combines the powerful regression capabilities of conventional numerical regression methods with the superior solution-finding ability of genetic programming
AHP Analytical Hierarchy Process	A structured technique for making complex decisions, where in the traditional formulation, expert judgments are presented in the form of exact numbers (proportions) to form a matrix for comparing criteria and alternatives
RM Ranking Model	Simple models that rank pipes by a given variable or combination of variables, and other rank boosting algorithms that iteratively update the output variables of a dataset in search of improvements in a given quality metric
DT Decision Trees	Models that allow solving problems of classification, hierarchy and regression. DT is used for data mining (predicting the value of a target variable based on several input variables)
RF Random forest	A collective learning algorithm that consists of multiple decision trees, where each decision tree is trained independently on a random subset of data. The larger the number of trees, the better the result
SVM Support Vector Machines	A linear algorithm used in classification and regression analysis problems. The algorithm creates a line or hyperplane that separates the data into classes
GNN Graph Neural Network	A type of neural network based on graph theory — directly working with the structure of a graph (a data structure consisting of two components: nodes — objects, and edges — connections between them). A typical application of GNN is node classification. It can be used, for example, to integrate hydraulic and topological characteristics of a water supply network
ANFIS Adaptive neuro-fuzzy network	It is a type of artificial neural network based on the Takagi – Sugeno fuzzy inference system. This system integrates the principles of ANN with the principles of fuzzy logic (hybrid system). ANFIS is a universal evaluator based on observed data: the rule is the evaluator, and the result is the assessment
KNN Kohonen Neural Networks	The neural network is configured using a learning algorithm (successive approximation method) without supervision, so it is also called a self-organizing map. It is used mainly for classification, compression, pattern recognition and diagnostics. KNN, unlike a multilayer neural network, is very simple; it consists of two layers: input and output. It adapts not to a reference output value, but to patterns in the input data

(ANN), which are rapidly developing at present. A single study can use different models and algorithms with/without the use of ANN. The study of ML methods and their application in this topic shows that the problem can be modeled in different ways. This is reflected in the different output variables that were used (time to failure, risk index per section, failure probability, localization of vulnerable sections, failure rate, etc.). The implementation of processing methods, such as sampling strategies or variable transformations, are also combined with the most promising models (ANN, KNN, LR, GP, SVR, etc.) (Table 2).

The following patterns are observed:

- a tendency for the same pipes to fail more frequently over a number of years, as evidenced by a positive cor-

relation between the number of previous pipe failures and the output variable. Utilities should review their maintenance recommendations and look for potential weak spots;

- according to the analysis of the annual failure rate per kilometer, smaller diameter pipes, as well as older pipes, have a significantly higher failure rate;
- the failure rate of concrete pipes is about 0.65 failures/km year, which indicates a serious problem associated with this material.

For the sustainable development of centralized water supply systems, water utilities need to ensure reliable and continuous data collection — this is the most important practice that will help make reliable decisions not only in the present but also in the future. Research shows

Table 2. Forecast models and output variables of some studies — forecasting pipeline failures in water supply networks

Model	Output variable and reference
BBN, SVR	Probability of failure [2]
FL	Failure risk index considering material, age, length and diameter of pipes [3]
GP	Time to pipeline failure [4, 5]
GA	Localization and size of leaks [6, 7]
RM, LR, NB, SM	Number of pipeline failures [8]
RM	Risk index [9]
BBN	Number of pipe damages [10]
SVR, CL, FL (ANN)	Failure rate [11]
GT, SVM (ANN)	Leak localization [12]
SVM, RF	Localization of leaks and reduction of excess pressure [13]
FL, AHP	Condition of pipes [14]
EPR	Number of pipeline failures [15]
LR	Time to pipeline failure [16]
RM, LR, SVM (ANN)	Probability of failure [17]
DT, SM, RM	Time to pipeline failure [18]
DT, BBN (ANN)	Probability of failure [19]
GLM, DT (ANN)	Time to pipeline failure [20]
BBN	Probability of failure [21]
GNN (ANN)	Localization of vulnerable areas by pressure [22, 23]
FL, ANFIS (ANN)	Remaining service life of pipes [24]
FL, ANFIS (ANN)	Localization of vulnerable areas [25–27]
FL, ANFIS (ANN)	Failure rates by pipe diameter and material [28]
DT	Time to pipeline failure [29]
RF	Localization of vulnerable areas [30–32]
CVM, RF (ANN)	Differentiation and identification of failure events [33]
KNN Kohonen algorithm (ANN)	Failure rate, probability of failure-free operation, availability factor [34, 35]

an increase and improvement in the reliability of data on pipeline failures when using SCADA systems based on Geographic Information Systems (GIS). The goal of a water utility should be to recognize the value of data, rather than save on sources and time to develop a reliable and high-quality data collection policy. The simplest factors that water utilities can collect in their databases are, for example: pipe diameter, section length, pipe age, pressure, soil type. In our opinion, the pressure (or difference) in the network itself is not a sign of an accident. This is undoubtedly an important parameter, but it should be considered together with the number of network failures (accidents) in sections.

Beginning of the use of Kohonen neural network algorithms (KNN) in Russia [34, 35], as well as studies implementing the conclusion on the correctness of the design and operation of the system [36], is not accidental. It indicates the presence of the only neural network software translated into Russian STATISTICA Automated Neural Networks (vendor StatSoft Russia)¹ contains the most modern neural network training algorithms (the conjugate gradient method, the Levenberg-Marquardt algorithm, BFGS, the Kohonen algorithm).

¹ STATISTICA Automated Neural Networks. URL: <https://лицензионныйсофт.рф/catalog/view/405/?ysclid=lwkqdt5dum161804109>

The software is designed for data analysis, visualization, forecasting and statistical analysis, which allows it to be used in predicting pipe failures in water supply networks.

The Kohonen network, unlike the multilayer ANN, is very simple; it consists of two layers: input and output. ML according to Kohonen’s rule refers to competitive learning methods. In the neural network layer, the weights of only one winner neuron are changed, its weights are recognized as the closest to the values of the input signal. The Kohonen network is trained using the method of successive approximations. During the ML process, data is fed to the inputs, but the neural network is adjusted not to the reference value of the output, but to the patterns in the input data. The Kohonen neural network is configured using an unsupervised learning algorithm (that is why it is called a self-organizing map) and is used mainly for classification, compression, pattern recognition and diagnostics.

In addition to the above methods, acoustic and ultrasonic methods for monitoring the condition of underground pipeline networks based on the propagation of volumetric and directional waves (noise) are beginning to develop rapidly. Namely, vibration measurements and evaluation of the spectral characteristics of leak noise using accelerometers, hydrophones, fiber optic sensors and ultrasonic (above 20 kHz) methods [37–40]. Although these methods were applied to pipes manually,

they are suitable for use in combination with autonomous inspection robots to detect the occurrence of defects inside pipes. Corresponding ML methods for predicting leak locations based on such data are being studied:

- Generative Adversarial Network (GAN) is a novel approach to ML that combines game theory, probabilistic modeling, and information theory [38]. GAN consists of two neural networks, a generator and a discriminator, which are trained in an adversarial manner to generate realistic data;
- Regression ML algorithms based on k -nearest neighbors (k -NN) and support vector machines (SVM) [39];
- Support Vector Machine (SVM), Artificial Neural Network (ANN) and Deep Learning (DL) leak detection models (Learning) have demonstrated generally stable performance and high accuracy [40].

CONCLUSIONS

For the sustainable development of centralized water supply systems, water utilities need to ensure reliable and continuous data collection — this is a key practice that will help make reliable decisions based on artificial

intelligence predictions after the machine learning phase. The simplest factors that water utilities can collect in their databases are, for example: pipe diameter, section length, pipe age, pressure, soil type. In our opinion, the pressure (or difference) in the network itself is not a sign of an accident. This is undoubtedly an important parameter, but it should be considered together with the number of network failures (accidents) in sections.

Trends and use of machine learning in water supply network management revealed the use of 18 algorithms to solve problems related to water supply system leaks. The output variables can be: failure rate, failure probability, risk index, time to failure, number of failures, pipe condition, localization of vulnerable areas, remaining service life of pipes, probability of failure-free operation, availability factor. The beginning of the use of Kohonen neural network algorithms in Russia is associated with the availability of Russian-language software STATISTICA Automated Neural Networks.

Information is presented on developing acoustic and ultrasonic methods for monitoring the condition of underground pipeline networks, based on the propagation of volumetric and directional waves (noise) and the corresponding ML methods.

REFERENCES

1. Robles-Velasco A. *A machine learning approach to predict pipe failures in water distribution networks*. 2022; 151. URL: <https://idus.us.es/handle/11441/131484>
2. Weeraddana D., Hapuarachchi H., Kumaraperuma L., Khoa N.L.D., Cai C. Long-term water pipe condition assessment: a semiparametric model using gaussian process and survival analysis. *Lecture Notes in Computer Science*. 2020; 487-499. DOI: 10.1007/978-3-030-47436-2_37
3. Pouri Z., Heidarimozaffar M. Spatial analysis and failure management in water distribution networks using fuzzy inference system. *Water Resources Management*. 2022; 36(6):1783-1797. DOI: 10.1007/s11269-022-03104-5
4. Sattar A.M.A., Gharabaghi B., McBean E.A. Prediction of timing of watermain failure using gene expression models. *Water Resources Management*. 2016; 30(5):1635-1651. DOI: 10.1007/s11269-016-1241-x
5. Sangroula U., Han K.H., Koo K.M., Gnawali K., Yum K.T. Optimization of water distribution networks using genetic algorithm based SOP-WDN program. *Water*. 2022; 14(6):851. DOI: 10.3390/w14060851
6. Primin O.G., Gromov G.N. Hydraulic calculations improvements of water supply systems by using electronic models. *International Journal for Computational Civil and Structural Engineering*. 2018; 14(2):141-148. DOI: 10.22337/2587-9618-2018-14-2-141-148. EDN OYBKZZ. (rus.).
7. Primin O.G., Gromov G.N., Ten A.E. Algorithms for constructing and calibrating electronic models of water supply system. *Vestnik MGSU* [Proceedings of the Moscow State University of Civil Engineering]. 2018; 13(7):847-854. DOI: 10.22227/1997-0935.2018.7.847-854 (rus.).
8. Kleiner Y., Rajani B. Comparison of four models to rank failure likelihood of individual pipes. *Journal of Hydroinformatics*. 2012; 14(3):659-681. DOI: 10.2166/hydro.2011.029
9. Wang R., Dong W., Wang Y., Tang K., Yao X. Pipe failure prediction: A data mining method. *2013 IEEE 29th International Conference on Data Engineering (ICDE)*. 2013; 1208-1218. DOI: 10.1109/ICDE.2013.6544910
10. Francis R.A., Guikema S.D., Henneman L. Bayesian belief networks for predicting drinking water distribution system pipe breaks. *Reliability Engineering & System Safety*. 2014; 130:1-11. DOI: 10.1016/j.res.2014.04.024
11. Aydogdu M., Firat M. Estimation of failure rate in water distribution network using fuzzy clustering and LS-SVM methods. *Water Resources Management*. 2015; 29(5):1575-1590. DOI: 10.1007/s11269-014-0895-5
12. Komba G.M., Mathonsi T.E., Owolawi P.A. Water pipeline leak detection and localisation in water distribution networks. *2023 International Conference on Emerging Trends in Networks and Computer Communications (ETNCC)*. 2023; 140-145. DOI: 10.1109/ETNCC59188.2023.10284934
13. Komba G.M., Mathonsi T.E., Owolawi P.A. Optimizing leak detection and location in water distribution networks.

bution networks using SVM-RF algorithm. *2024 15th International Conference on Mechanical and Intelligent Manufacturing Technologies (ICMIMT)*. 2024; 27-33. DOI: 10.1109/ICMIMT61937.2024.10585935

14. Amaitik N.M., Buckingham C.D. Developing a hierarchical fuzzy rule-based model with weighted linguistic rules: A case study of water pipes condition prediction. *2017 Computing Conference*. 2017; 30-40. DOI: 10.1109/SAI.2017.8252078

15. Farmani R., Kakoudakis K., Behzadian K., Butler D. Pipe failure prediction in water distribution systems considering static and dynamic factors. *Procedia Engineering*. 2017; 186:117-126. DOI: 10.1016/j.proeng.2017.03.217

16. Rifaai T.M., Abokifa A.A., Sela L. Integrated approach for pipe failure prediction and condition scoring in water infrastructure systems. *Reliability Engineering & System Safety*. 2022; 220:108271. DOI: 10.1016/j.ress.2021.108271

17. Fan X., Wang X., Zhang X., Yu X. Machine learning based water pipe failure prediction: The effects of engineering, geology, climate and socio-economic factors. *Reliability Engineering & System Safety*. 2022; 219:108185. DOI: 10.1016/j.ress.2021.108185

18. Snider B., McBean E.A. Watermain breaks and data: The intricate relationship between data availability and accuracy of predictions. *Urban Water Journal*. 2020; 17(2):163-176. DOI: 10.1080/1573062X.2020.1748664

19. Giraldo-González M.M., Rodríguez J.P. Comparison of statistical and machine learning models for pipe failure modeling in water distribution networks. *Water*. 2020; 12(4):1153. DOI: 10.3390/w12041153

20. Almheiri Z., Meguid M., Zayed T. Intelligent approaches for predicting failure of water mains. *Journal of Pipeline Systems Engineering and Practice*. 2020; 11(4). DOI: 10.1061/(ASCE)PS.1949-1204.0000485

21. Tang K., Parsons D.J., Jude S. Comparison of automatic and guided learning for Bayesian networks to analyse pipe failures in the water distribution system. *Reliability Engineering & System Safety*. 2019; 186:24-36. DOI: 10.1016/j.ress.2019.02.001

22. Shekofteh M., Jalili Ghazizadeh M., Yazdi J. A methodology for leak detection in water distribution networks using graph theory and artificial neural network. *Urban Water Journal*. 2020; 17(6):525-533. DOI: 10.1080/1573062X.2020.1797832

23. Peng S., Cheng J., Wu X., Fang X., Wu Q. Pressure sensor placement in water supply network based on graph neural network clustering method. *Water*. 2022; 14(2):150. DOI: 10.3390/w14020150

24. Tavakoli R., Sharifara A., Najafi M. Artificial neural networks and adaptive neuro-fuzzy models to predict remaining useful life of water pipelines. *World Envi-*

ronmental and Water Resources Congress 2020. 2020; 191-204. DOI: 10.1061/9780784482988.019

25. Romanov R.V., Kochetkova S.S. Application of a neural network approach for localization of problem areas of a centralized water supply system. *Third International Conference on Optics, Computer Applications, and Materials Science (CMSD-III 2023)*. 2024; 30. DOI: 10.1117/12.3025000

26. Mehran Jafari S., Bozorg-Haddad O., Reza Nikoo M. Application of artificial neural network and fuzzy logic in the urban water distribution networks pipe failure modelling. *Studies in Computational Intelligence*. 2022; 333-354. DOI: 10.1007/978-981-19-2519-1_16

27. Rashid A., Kumari S. *Optimal design of water distribution network using neuro – fuzzy technique*. 2021. DOI: 10.21203/rs.3.rs-915481/v1

28. Gheibi M., Moezzi R., Taghavian H., Wacławek S., Emrani N., Mohtasham M. et al. A risk-based soft sensor for failure rate monitoring in water distribution network via adaptive neuro-fuzzy interference systems. *Scientific Reports*. 2023; 13(1). DOI: 10.1038/s41598-023-38620-w

29. Yang Y., Hu Y., Zheng J. A decision tree approach to the risk evaluation of urban water distribution network pipes. *Safety*. 2020; 6(3):36. DOI: 10.3390/safety6030036

30. Lučin I., Lučin B., Čarija Z., Sikirica A. Data-driven leak localization in urban water distribution networks using big data for random forest classifier. *Mathematics*. 2021; 9(6):672. DOI: 10.3390/math9060672

31. Lucin I., Carija Z., Druzeta S., Lucin B. Detailed leak localization in water distribution networks using random forest classifier and pipe segmentation. *IEEE access*. 2021; 9:155113-155122. DOI: 10.1109/ACCESS.2021.3129703

32. Marvin G., Grbčić L., Družeta S., Kranjčević L. Water distribution network leak localization with histogram-based gradient boosting. *Journal of Hydroinformatics*. 2023; 25(3):663-684. DOI: 10.2166/hydro.2023.102

33. Parajuli U., Shin S. Identifying failure types in cyber-physical water distribution networks using machine learning models. *AQUA — Water Infrastructure, Ecosystems and Society*. 2024; 73(3):504-519. DOI: 10.2166/aqua.2024.264

34. Timashev S.A., Makeeva T.V. Assessment and prediction of water supply network reliability under information shortage using artificial neural networks. *ASCE Inspire* 2023. 2023; 733-741. DOI: 10.1061/978078-4485163.085

35. Timashev S.A., Makeeva T.V. *Assessing the reliability of the urban water supply network under information deficit using artificial neural networks*. Ekaterinburg, Publishing house of the Ural University, 2023; 78. (rus.).

36. Karambirov S.N., Umansky P.M. Cluster analysis of parts of water supply network. *Prirodoobustroystvo*. 2016; 1:23-27. EDN VVWITX. (rus.).
37. Scussell O., Brennan M.J., Almeida F.C., Muggleton J.M., Rustighi E., Joseph P.F. Estimating the spectrum of leak noise in buried plastic water distribution pipes using acoustic or vibration measurements remote from the leak. *Mechanical Systems and Signal Processing*. 2021; 147:107059. DOI: 10.1016/j.ymssp.2020.107059
38. Liu R., Zayed T., Xiao R. Advanced acoustic leak detection in water distribution networks using integrated generative model. *Water Research*. 2024; 254:121434. DOI: 10.1016/j.watres.2024.121434
39. Yussif A.M., Sadeghi H., Zayed T. Application of machine learning for leak localization in water supply networks. *Buildings*. 2023; 13(4):849. DOI: 10.3390/buildings13040849
40. Fares A., Tijani I.A., Rui Z., Zayed T. Leak detection in real water distribution networks based on acoustic emission and machine learning. *Environmental Technology*. 2023; 44(25):3850-3866. DOI: 10.1080/09593330.2022.2074320

Received September 4, 2024.

Adopted in revised form on September 4, 2024.

Approved for publication on September 20, 2024.

B I O N O T E S : **Viktor I. Bazhenov** — Doctor of Technical Sciences, Professor, Executive Director; **JSC “Water and Wastewater”**; 7 Bolshoy Strochenovskiy pereulok, Moscow, 115054, Russian Federation; ID RSCI: 266644, Scopus: 57202817636, ORCID: 0000-0002-6619-1212; bazhenov@pump.ru;

Oleg G. Primin — Doctor of Technical Sciences, chief researcher; **Research Institute of Building Physics of the Russian Academy of Architecture and Construction Sciences**; 21 Lokomotivny pr., Moscow, 127238, Russian Federation; Professor; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; ID RSCI: 414862; tepper2007@yandex.ru;

Vladimir V. Bazhenov — postgraduate student, laboratory assistant; **Bauman Moscow State Technical University (BMSTU)**; 5 2nd Baumanskaya st., Moscow, 105005, Russian Federation; ID RSCI: 1228325; Bazhenov VladimirV@gmail.com.

Contribution of the authors:

Viktor I. Bazhenov — scientific supervision, idea, writing of the original text.

Oleg G. Primin — data gathering, supervision, scientific editing of the text.

Vladimir V. Bazhenov — identification of machine learning algorithms at the original literature, editing of the text.

The authors declare no conflict of interest.