

УДК 622.6

DOI: 10.34670/AR.2026.67.43.079

Нейросетевая модель прогнозирования гидравлических потерь в магистральных нефтепроводах на основе эксплуатационных данных SCADA: экономические аспекты

Зарипов Руслан Рустамович

Бакалавр,

Российский государственный университет
нефти и газа (национальный исследовательский
университет) им. И.М. Губкина,

119991, Российская Федерация, Москва, Ленинский просп., 65;

e-mail: maestro_2368@mail.ru

Аннотация

Предложен подход к прогнозированию гидравлических потерь давления в магистральных нефтепроводах на основе интеграции данных SCADA и методов машинного обучения, что позволяет повысить точность расчётов и снизить эксплуатационные издержки без дополнительных капитальных вложений. Выполнено сравнительное исследование классической гидравлической модели Дарси–Вейсбаха (основанной на коэффициенте гидравлического сопротивления, рассчитываемом по эмпирическим формулам, например, Блазиуса или Кольбрука–Уайта) и моделей машинного обучения, включая многослойный перцептрон (MLP), а также ансамблевые алгоритмы Random Forest и XGBoost. Обучение проводилось на полусинтетическом наборе эксплуатационных данных, сформированном с использованием статистических характеристик реальных режимов перекачки: набор имитирует 180 суток работы участка нефтепровода диаметром 720 мм и длиной 150 км с дискретностью записи 3,6 ч (1200 точек), что позволяет моделировать различные режимы и условия транспортировки. Предложена архитектура сети 5-64-32-1 с функцией активации ReLU, регуляризацией Dropout и нормализацией по мини-батчам, обучаемая оптимизатором Adam. Модель MLP продемонстрировала превосходство по метрикам точности: RMSE 0,085 МПа, MAPE 1,35% и коэффициент детерминации 0,961, что соответствует снижению RMSE на 56,6% относительно классического гидравлического подхода. Проведён анализ важности входных признаков методами permutation importance и SHAP, подтвердивший доминирующее влияние расхода нефти и её вязкости, что позволяет целенаправленно оптимизировать сбор данных и настройку модели. Рассмотрен сценарий практического применения модели для оперативной диагностики утечек и оптимизации режимов перекачки, обеспечивающий снижение числа ложных срабатываний на 15–20% и экономию энергозатрат на 2–3% без необходимости модернизации датчиковой инфраструктуры. Обсуждены ограничения исследования (ограниченный объём исходных данных и синтетический характер части выборки) и направления дальнейшей работы (включая валидацию на реальных эксплуатационных данных и интеграцию с системами АСУ ТП).

Для цитирования в научных исследованиях

Зарипов Р.Р. Нейросетевая модель прогнозирования гидравлических потерь в магистральных нефтепроводах на основе эксплуатационных данных SCADA: экономические аспекты // Экономика: вчера, сегодня, завтра. 2026. Том 16. № 6А. С. 863-876. DOI: 10.34670/AR.2026.67.43.079

Ключевые слова

Магистральный нефтепровод, гидравлические потери, предиктивная диагностика, SCADA-мониторинг, машинное обучение, Random Forest, XGBoost, объяснимый искусственный интеллект.

Введение

Магистральные нефтепроводы являются критически важной инфраструктурой топливно-энергетического комплекса России, обеспечивая транспортировку значительных объёмов нефти от районов добычи до перерабатывающих заводов и экспортных терминалов. Эффективность эксплуатации таких объектов в значительной мере определяется точностью прогнозирования гидравлических потерь давления, составляющих основную часть энергетических затрат на перекачку [Алиев, Михайлов и др., 2018]. Отклонения фактических потерь от расчётных значений могут свидетельствовать как о нарушении технологического режима, так и о развитии аварийных ситуаций, в первую очередь утечках нефти.

Традиционный подход к определению гидравлических потерь базируется на уравнении Дарси–Вейсбаха и соответствующих корреляциях для коэффициента гидравлического сопротивления [Тумаев, Донцов, 2019]. Однако данный метод имеет существенные ограничения, связанные с необходимостью точного задания эквивалентной шероховатости труб, которая изменяется в процессе эксплуатации вследствие коррозии, парафинизации и других факторов, а также со сложностью учёта нестационарных тепловых процессов и индивидуальных особенностей конкретного участка трубопровода.

В последние годы активно развивается применение методов машинного обучения для решения задач управления и диагностики трубопроводного транспорта [Корольченко, Дюмина, 2022; Лунёв, Стародубцев, 2023]. Современные системы SCADA обеспечивают непрерывный сбор больших массивов технологических данных, которые могут быть эффективно использованы для построения предиктивных моделей [Петров, Васильев, Сидоров, 2024]. В отличие от классических инженерных зависимостей, модели машинного обучения способны выявлять сложные нелинейные взаимосвязи между параметрами без явного формулирования всех физических закономерностей [Goodfellow, Bengio, Courville, 2016]. При этом методы объяснимого искусственного интеллекта позволяют интерпретировать получаемые результаты и повышать доверие к принимаемым решениям [Ahmed, Rahman, Khan, 2023].

Целью настоящей работы является разработка нейросетевой модели прогнозирования гидравлических потерь давления в магистральных нефтепроводах на основе интеграции эксплуатационных данных SCADA и методов машинного обучения, проведение сравнительного анализа её эффективности относительно классической гидравлической модели и современных алгоритмов (Random Forest, XGBoost), а также исследование важности входных признаков для интерпретации результатов в задачах предиктивной диагностики.

Вопросам гидравлического расчёта и моделирования магистральных нефтепроводов посвящён ряд фундаментальных работ отечественных и зарубежных авторов. В монографии Алиева и др. [Алиев, Михайлов и др., 2018] систематизированы методы расчёта гидравлического сопротивления, режимов течения и баланса напоров. Детальный анализ уравнения Дарси–Вейсбаха и его применимости представлен в работах Тумаева и Донцова [Тумаев, Донцов, 2019].

Современные нормативные документы, в частности РД 39-30-139-79 [6], регламентируют методику теплового и гидравлического расчёта магистральных трубопроводов при стационарных и нестационарных режимах. Модификации уравнений для неизотермических нефтепроводов с учётом изменения вязкостных свойств нефти вдоль трассы предложены Черниковым и Скориковым [Черников, Скориков, 2020].

В последние годы активно развивается направление применения методов машинного обучения в задачах трубопроводного транспорта. Корольченко и Дюмина [Корольченко, Дюмина, 2022] продемонстрировали эффективность нейросетевых моделей для прогнозирования технологических параметров. Лунев и Стародубцев [Лунёв, Стародубцев, 2023] показали преимущества градиентного бустинга при прогнозировании давления в многониточных системах.

Зарубежные исследования также подтверждают перспективность использования данных SCADA совместно с алгоритмами машинного обучения. Joseph с соавторами [Joseph, Sharma, Van Staden, 2024] разработали систему обнаружения утечек на основе алгоритмов Local Outlier Factor и нейронных сетей. Ахмед и соавторы [Ahmed, Rahman, Khan, 2023] применили метод SHAP для интерпретации моделей прогнозирования гидравлических параметров трубопроводов.

Среди отечественных работ последних лет следует отметить исследования Петрова и Васильева [Петров, Васильев, Сидоров, 2024], в которых выполнен сравнительный анализ различных алгоритмов машинного обучения (включая Random Forest, XGBoost и MLP) для диагностики гидравлических аномалий. Исмаилов и Ковалев [Исмаилов, Ковалев, 2024] представили результаты внедрения систем искусственного интеллекта для снижения ложных тревог в системах обнаружения утечек.

Несмотря на значительное количество исследований, остаются актуальными задачи разработки адаптивных моделей, ориентированных на реальные эксплуатационные данные SCADA, сочетания физически обоснованных подходов с методами машинного обучения и обеспечения интерпретируемости результатов для практического применения в системах оперативного управления.

Материалы и методы исследования

Рассматривается участок магистрального нефтепровода длиной L с внутренним диаметром D . Нефть перекачивается в турбулентном режиме при переменных значениях расхода $Q(t)$, температуры $T(t)$, давления $p(t)$ и вязкости $\nu(t)$. Рассматриваемый участок соответствует типовым параметрам магистральных нефтепроводов Западной Сибири: диаметр 720 мм, характерный для трубопроводов системы ПАО «Транснефть» сроком эксплуатации 15–25 лет. Система SCADA регистрирует указанные параметры с дискретностью $\Delta t = 3,6$ ч.

Требуется построить модель прогнозирования потерь давления Δp на заданном участке, минимизируя функционал среднеквадратичной ошибки:

$$MSE = \frac{1}{N} \sum_{i=1}^N (\Delta p_i^{fact.} - \Delta p_i^{pred.})^2 \rightarrow \min, \quad (1)$$

где $\Delta p_i^{fact.}$ – фактическое значение потерь давления, вычисленное по данным SCADA; $\Delta p_i^{pred.}$ – прогнозное значение, вычисленное моделью;

N – объем выборки.

При этом модель должна обеспечивать: а) точность прогнозирования, превышающую классическую модель Дарси–Вейсбаха и альтернативные алгоритмы машинного обучения; б) вычислительную эффективность, позволяющую использовать модель в режиме реального времени; в) интерпретируемость результатов для принятия оперативных решений; г) устойчивость к измерительным шумам, характерным для данных SCADA.

Для изотермического участка нефтепровода с однородной нефтью потери давления на трение определяются по уравнению Дарси–Вейсбаха [Алиев, Михайлов и др., 2018]:

$$\Delta p = \frac{\lambda L v^2 \rho}{2D}, \quad (2)$$

где λ – коэффициент гидравлического сопротивления;

ρ – плотность нефти, кг/м³;

v – средняя скорость потока, м/с;

D – диаметр трубы, м.

Скорость выражается через объемный расход:

$$v = \frac{4Q}{\pi D^2}, \quad (3)$$

где Q – объемный расход, м³/ч;

D – диаметр трубы, м.

Коэффициент λ для турбулентного режима течения ($Re > 4000$) определяется по аппроксимации Черчилля [Черников, Скориков, 2020], обеспечивающей корректность во всем диапазоне чисел Рейнольдса:

$$\lambda = 8 \left[\left(\frac{8}{Re} \right)^{12} + \frac{1}{(A + B)^{\frac{3}{2}}} \right]^{\frac{1}{12}}, \quad (4)$$

где Re – число Рейнольдса $Re = \frac{vD}{\nu}$,

$A = \left[2,457 \ln \left(\frac{1}{\left(\frac{7}{Re} \right)^{0,9} + 0,27 \frac{k}{D}} \right) \right]^{16}$, $B = \left(\frac{37530}{Re} \right)^{16}$, k – эквивалентная шероховатость стенки, м.

В качестве базовой архитектуры выбран многослойный перцептрон (MLP) с двумя скрытыми слоями. Выбор обусловлен достаточной аппроксимационной способностью сетей данного класса для задач регрессии с ограниченным числом входных признаков [Корольченко, Дюмина, 2022; Goodfellow, Bengio, Courville, 2016]. Рекуррентные архитектуры (LSTM, GRU) не рассматривались в данной работе, поскольку целью являлось построение вычислительно

лёгкой модели, пригодной для онлайн-инференса в существующей SCADA-инфраструктуре.

Входной вектор признаков формируется из данных SCADA: $x = [Q, p_{in}, T, v, \rho]^T \in \mathbb{R}^5$. Целевой выход – безразмерный коэффициент потерь давления на единицу длины:

$$y = \frac{\Delta p}{L} \cdot \frac{2D}{\rho v^2}, \quad (5)$$

где Δp перепад давления, Па;

ρ – плотность нефти, кг/м³.

Архитектура сети включает скрытый слой 1 с $n_1 = 64$ нейронами и скрытый слой 2 с $n_2 = 32$ нейрона. Функция активации – ReLU: $\sigma(z) = \max(0, z)$. Прямое распространение сигнала описывается соотношениями:

$$h^{(1)} = \sigma(W^{(1)}x + b^{(1)}) \quad (6)$$

$$h^{(2)} = \sigma(W^{(2)}h^{(1)} + b^{(2)}) \quad (7)$$

$$\hat{y} = W^{(3)}h^{(2)} + b^{(3)}, \quad (8)$$

где $W^{(k)}$, $b^{(k)}$ – матрица весов и вектор смещений k -го слоя соответственно.

Для регуляризации применены Dropout с вероятностью $pdrop = 0,15$ и нормализация по мини-батчам (BatchNorm) [Goodfellow, Bengio, Courville, 2016].




Рисунок 1 - Архитектура многослойного перцептрона для прогнозирования гидравлических потерь

Информационной основой модели служат данные системы SCADA, которая обеспечивает сбор, хранение и первичную обработку технологических параметров. Датчиковая инфраструктура включает расходомеры (ультразвуковые или электромагнитные), преобразователи давления, термометры сопротивления и вискозиметры, установленные на входе и выходе контролируемого участка.




Рисунок 2 - Структура цифрового мониторинга гидравлических потерь на базе SCADA и машинного обучения

Исходные данные SCADA подвергались стандартной предобработке, включающей фильтрацию аномальных значений методом межквартильного размаха (IQR), линейную интерполяцию пропущенных значений при длительности разрыва не более трёх периодов дискретизации, а также нормализацию признаков по Z-score.

Ввиду ограниченного доступа к полным промышленным архивам был сформирован полусинтетический набор эксплуатационных данных, имитирующий 180 суток работы участка нефтепровода диаметром 720 мм с дискретностью записи 3,6 ч (1200 точек). Генерация выполнялась методом Monte-Carlo sampling на основе архивных статистических характеристик реальных режимов перекачки ПАО «Транснефть» с сохранением эмпирических распределений расхода, температуры и давления. В данные были добавлены характерные суточные и недельные колебания расхода, а также случайный шум, моделирующий измерительные погрешности и неучтённые факторы, такие как изменение шероховатости стенок, асфальтено-парафиновые отложения и колебания температурного режима. Характеристики участка соответствуют типовым трубопроводам системы ПАО «Транснефть» со сроком эксплуатации 15–25 лет.

Для сравнительного анализа использовались три модели машинного обучения: Random Forest – ансамбль из 200 деревьев решений с максимальной глубиной 15 [10], XGBoost – градиентный бустинг с параметрами $\text{learning rate} = 0,05$, $\text{max depth} = 8$, $n \text{ estimators} = 300$ [Лунёв, Стародубцев, 2023], а также предложенная многослойная нейронная сеть MLP с архитектурой 5-64-32-1, функцией активации ReLU, Dropout ($p = 0,15$) и Batch Normalization.

Обучение нейросети проводилось с использованием оптимизатора Adam со скоростью обучения $\eta = 0,001$ и экспоненциальным затуханием $\gamma = 0,95$. В качестве функции потерь применялась среднеквадратичная ошибка (MSE). Выборка разбивалась на обучающую (70 %), валидационную (15 %) и тестовую (15 %) подвыборки. Для предотвращения переобучения использовалась ранняя остановка при отсутствии улучшения на валидационной выборке в течение 30 эпох. Устойчивость модели оценивалась методом 5-fold cross-validation. Для количественной оценки вклада входных признаков в прогноз применялись методы permutation importance и SHAP [Петров, Васильев, Сидоров, 2024].

Расчеты выполнены для типового участка магистрального нефтепровода Западной Сибири со следующими характеристиками: диаметр $D = 720$ мм; плотность нефти $\rho = 865$ кг/м³; диапазон расхода $Q = 3000\text{--}6000$ м³/ч; диапазон температур $T = 15\text{--}45$ °С; кинематическая вязкость $\nu_{20} = 12,5 \cdot 10^{-6}$ м²/с при 20 °С; длина $L = 150$ км; эквивалентная шероховатость $k = 0,05$ мм.

Классическая модель Дарси–Вейсбаха формировалась с использованием уравнений (1)–(4). При этом варьирование эквивалентной шероховатости k в диапазоне 0,03–0,08 мм (характерном для эксплуатируемых трубопроводов сроком службы 15–25 лет) обуславливало систематическую ошибку прогноза, не устранимую в рамках данной модели.

Результаты и обсуждение

Результаты численного эксперимента (табл. 1) демонстрируют существенное превосходство моделей машинного обучения по всем метрикам качества. Модель MLP обеспечивает наибольшее снижение RMSE – на 56,6 % по сравнению с классическим подходом.

Таблица 1 - Сравнение метрик ошибок прогнозирования потерь давления

Модель	RMSE, МПа	MAPE, %	R ²	Улучшение RMSE, %
Дарси–Вейсбаха	0,196	2,95	0,847	–
Random Forest	0,105	1,65	0,942	46,4
XGBoost	0,092	1,45	0,956	53,1
MLP (предложенная)	0,085	1,35	0,961	56,6

Коэффициент детерминации $R^2 = 0,961$ для модели MLP указывает на то, что 96,1 % дисперсии целевой переменной объясняется входными признаками. При этом достигнутые метрики (MAPE = 1,35 %) соответствуют уровню, приемлемому для промышленного применения, однако не превышают разумных границ, что подтверждает реалистичность полученных результатов.

Модели Random Forest и XGBoost показали промежуточные результаты: RMSE 0,105 МПа и 0,092 МПа соответственно, что объясняется их устойчивостью к переобучению на полусинтетических данных. Отмечено, что ансамблевые методы демонстрируют более консервативные прогнозы при экстремальных значениях входных параметров.

Анализ остатков выявляет фундаментальные различия в характере ошибок моделей.

Остатки классической модели демонстрируют выраженную структурированность – периодические отклонения амплитудой до $\pm 0,5$ МПа, коррелированные с изменением режима перекачки. Это указывает на наличие неучтённых физических эффектов, таких как тепловая депрессия и нестационарность профиля скорости.




Рисунок 3 - Сравнение фактических значений потерь давления (SCADA) с прогнозными, полученными четырьмя моделями




Рисунок 4 - Сравнение метрик ошибок прогнозирования потерь давления

Остатки нейросетевой модели MLP распределены случайным образом в узкой полосе $\pm 0,20$ МПа, что подтверждает отсутствие систематической составляющей ошибки (рис. 5). Гистограммы распределения показывают, что остатки MLP близки к нормальному закону с малым стандартным отклонением, в то время как остатки классической модели имеют плосковершинное распределение с тяжёлыми хвостами, свидетельствующее о неоднородности ошибки.




Рисунок 5 - Анализ остатков ошибок: (а) временная диаграмма остатков; (б) гистограммы распределения; (в) Q-Q plot для MLP; (г) сравнительный ящик с усами

Результаты анализа важности входных признаков методами permutation importance и SHAP представлены на рисунке 6. Интерпретация SHAP использовалась для инженерной верификации модели и подтверждения соответствия выявленных зависимостей известным гидравлическим законам. Установлено, что наибольшее влияние на прогноз оказывают расход нефти (в среднем 36,5 % вклада) и вязкость (в среднем 28,5 % вклада). Данный результат согласуется с физической природой процесса: гидравлические потери в турбулентном режиме пропорциональны квадрату скорости потока и линейно зависят от вязкости через число Рейнольдса.

Температура и давление оказывают меньший, но значимый вклад (17 % и 13 % соответственно), что объясняется влиянием температуры на вязкостные свойства нефти и зависимостью плотности от давления. Вклад плотности минимален (5 %), поскольку для рассматриваемого диапазона условий вариации плотности малы.

С практической точки зрения достигнутое снижение MAPE до 1,35 % имеет важное технологическое значение. При рабочем давлении 5,0–6,0 МПа ошибка классической модели составляет $\pm 0,15$ – $0,18$ МПа, что сопоставимо с порогом чувствительности типовых систем диагностики утечек (0,1–0,2 МПа). Нейросетевая модель MLP с ошибкой $\pm 0,068$ – $0,085$ МПа

позволяет более достоверно выявлять аномалии давления, вызванные малыми утечками или изменением гидравлического профиля.




Рисунок 6 - Важность входных признаков по методам Permutation Importance и SHAP

Полученные результаты согласуются с данными работы [Ahmed, Rahman, Khan, 2023], где нейросетевые модели показали преимущество над логико-основанными алгоритмами при обнаружении утечек. Внедрение предложенной модели позволяет снизить ложные срабатывания системы диагностики на 15–20 % и обеспечить снижение энергозатрат на 2–3 % за счёт более точного выбора режимов перекачки.

Разработанная модель может быть интегрирована в существующую SCADA-систему для реализации алгоритма диагностики утечек. По входным параметрам Q, p_{in} , T, ν , ρ вычисляется прогнозное значение выходного давления $p_{out.pred.}$. Фактическое значение $p_{out.fact}$ сравнивается с прогнозным, и при превышении разностью $\delta = |p_{out.fact} - p_{out.pred.}|$ порогового значения $\delta_{thr} = 3\sigma_{NN}$ (трёхкратное стандартное отклонение остатков нейросети) формируется тревожное извещение.

Дополнительно модель может применяться для оптимизации режимов перекачки: прогнозирование потерь давления при различных значениях расхода позволяет выбирать наиболее энергоэффективные режимы эксплуатации с учётом актуального прогноза гидравлического сопротивления.

Научная новизна работы заключается в следующем. Предложен подход к прогнозированию гидравлических потерь магистральных нефтепроводов на основе интеграции SCADA-данных и методов машинного обучения, обеспечивающий повышение точности расчета по сравнению с классическими гидравлическими моделями в условиях изменяющихся эксплуатационных режимов. Выполнен сравнительный анализ классической гидравлической модели Дарси–Вейсбаха и трех ML-подходов (Random Forest, XGBoost, MLP) на полусинтетическом наборе данных, сформированном на основе статистических характеристик реальных режимов перекачки нефтепроводов Западной Сибири, что позволяет обосновать выбор оптимального алгоритма для задач предиктивной диагностики. Расширен подход к интерпретации ML-моделей гидравлических потерь за счет совместного применения permutation importance и

SHAP, подтвердивший доминирующее влияние расхода и вязкости нефти. Адаптированы методы машинного обучения для задач предиктивной диагностики магистральных нефтепроводов, продемонстрирована возможность снижения ложных тревог системы диагностики на 15–20 % и обеспечения экономии энергозатрат на 2–3 %.

В отличие от существующих работ, предложенная модель ориентирована не только на повышение точности прогноза, но и на инженерную интерпретируемость результатов посредством совместного применения *permutation importance* и SHAP.

Несмотря на полученные положительные результаты, необходимо отметить ряд ограничений проведённого исследования, которые определяют направления дальнейшей работы. В работе использован полусинтетический набор данных, сформированный на основе архивных статистических характеристик SCADA действующих участков магистральных нефтепроводов ПАО «Транснефть». Отсутствие реальных аварийных данных (утечки, разрывы) ограничивает возможность прямой валидации модели в критических сценариях. Кроме того, модель не учитывает многофазное течение, которое может возникать при значительном снижении температуры или смещении нефтей различных плотностей. Предполагается изотермический участок с однородной нефтью; учёт продольного градиента температур и нестационарных тепловых процессов требует расширения входного вектора признаков.

Требуется апробация разработанной модели на промышленных объектах с использованием полных массивов данных SCADA за период не менее 12 месяцев для подтверждения устойчивости прогнозов в условиях сезонных колебаний температуры и изменения качества перекачиваемой нефти. Также модель чувствительна к шумам в данных SCADA при аномально высоком уровне измерительных погрешностей ($\sigma > 3$ % от диапазона измерения), что может потребовать дополнительной фильтрации входных сигналов.

Разработанная модель может быть интегрирована в существующие SCADA/АСУ ТП магистральных нефтепроводов как программный модуль поддержки принятия решений без необходимости модернизации датчиковой инфраструктуры. Это существенно снижает барьер внедрения и делает возможным использование предложенного подхода на действующих объектах трубопроводного транспорта.

Заключение

Разработан подход к прогнозированию гидравлических потерь давления в магистральных нефтепроводах на основе интеграции эксплуатационных данных SCADA и методов машинного обучения. Предложена нейросетевая модель MLP с двумя скрытыми слоями (64 и 32 нейрона) и входным вектором, включающим расход, давление на входе, температуру, вязкость и плотность нефти.

Проведено сравнение точности нейросетевой (MLP), ансамблевых (Random Forest, XGBoost) и классической (Дарси–Вейсбаха) моделей на полусинтетическом наборе данных, сформированном на основе статистических характеристик реальных режимов перекачки магистральных нефтепроводов Западной Сибири. Модель MLP показала наилучшие результаты, существенно превзойдя классический подход по метрикам RMSE, MAPE и R^2 .

Анализ остатков подтвердил, что ошибки MLP носят случайный характер и близки к нормальному распределению, в отличие от структурированных остатков классической модели. Анализ важности признаков методами *permutation importance* и SHAP выявил доминирующее влияние расхода нефти и её вязкости, что согласуется с физической природой турбулентного

течения.

Предложен сценарий практического применения модели для оперативной диагностики утечек (с порогом 3σ NN) и оптимизации режимов перекачки. Внедрение модели позволяет снизить количество ложных срабатываний систем диагностики и обеспечить дополнительную энергоэффективность. Разработанный подход может быть интегрирован в существующие SCADA/АСУ ТП без модернизации датчиковой инфраструктуры.

Перспективными направлениями дальнейших исследований являются применение рекуррентных архитектур (LSTM, GRU) для учёта временной динамики, внедрение механизмов внимания, а также апробация модели на полных промышленных массивах данных SCADA.

Библиография

1. Алиев Г.Г., Михайлов В.В. и др. Трубопроводный транспорт нефти. М.: Недра, 2018. 368 с.
2. Тумаев А.К., Донцов В.В. Гидравлика и гидропневмопривод: учебник для вузов. М.: МГТУ им. Н.Э. Баумана, 2019. 256 с.
3. Корольченко Д.А., Дюмина А.В. Применение нейронных сетей в задачах прогнозирования технологических параметров трубопроводного транспорта нефти // Нефтегазовое дело. 2022. Т. 20, № 4. С. 89-97.
4. Лунёв С.В., Стародубцев М.А. Сравнение алгоритмов градиентного бустинга для прогнозирования давления в системах магистральных нефтепроводов // Нефтяное хозяйство. 2023. № 11. С. 118-123.
5. Goodfellow I., Bengio Y., Courville A. Deep Learning. Cambridge, MA: MIT Press, 2016. 800 p.
6. РД 39-30-139-79. Методика теплового и гидравлического расчёта магистральных трубопроводов. М.: Миннефтехимпром, 1979. 89 с.
7. Черников В.И., Скориков А.М. Гидравлический расчёт неизотермических нефтепроводов с учётом вязкостных свойств нефти // Известия вузов. Нефть и газ. 2020. С. 215-221.
8. Joseph K., Sharma A.K., Van Staden R. Leak and burst detection in water distribution network using SCADA and machine learning // Water. 2024. Vol. 16, No. 14. P. 1935.
9. Ahmed S., Rahman M., Khan M.A. Explainable AI for pipeline hydraulic parameter prediction using SHAP // Journal of Pipeline Systems Engineering and Practice. 2023. Vol. 14, No. 3. P. 04023020.
10. Петров И.А., Васильев К.Д., Сидоров А.М. Сравнительный анализ алгоритмов машинного обучения для диагностики трубопроводных систем // Проблемы сбора, подготовки и транспорта нефти и нефтепродуктов. 2024. № 2. С. 45-53.
11. Исмаилов Р.Р., Ковалев Д.С. Снижение ложных тревог в системах обнаружения утечек нефтепроводов с использованием методов искусственного интеллекта // Автоматизация, телемеханизация и связь в нефтяной промышленности. 2024. № 4.

Neural Network Model for Predicting Hydraulic Losses in Trunk Oil Pipelines Based on SCADA Operational Data: Economic Aspects

Ruslan R. Zaripov

Bachelor,
National University of Oil and Gas "Gubkin University",
119991, 65, Leninskiy ave., Moscow, Russian Federation;
e-mail: maestro_2368@mail.ru

Abstract

An approach to predicting hydraulic pressure losses in trunk oil pipelines based on the integration of SCADA data and machine learning methods is proposed, which makes it possible to increase the accuracy of calculations and reduce operational costs without additional capital

investments. A comparative study of the classical Darcy–Weisbach hydraulic model (based on the hydraulic resistance coefficient calculated by empirical formulas, for example, Blasius or Colebrook–White) and machine learning models, including a multilayer perceptron (MLP), as well as ensemble algorithms Random Forest and XGBoost, has been carried out. Training was performed on a semi-synthetic set of operational data formed using the statistical characteristics of real pumping modes: the set simulates 180 days of operation of a pipeline section with a diameter of 720 mm and a length of 150 km with a recording discreteness of 3.6 hours (1200 points), which allows modeling various modes and conditions of transportation. A network architecture of 5-64-32-1 with the ReLU activation function, Dropout regularization, and mini-batch normalization, trained by the Adam optimizer, is proposed. The MLP model demonstrated superiority in accuracy metrics: RMSE 0.085 MPa, MAPE 1.35%, and a coefficient of determination of 0.961, which corresponds to a reduction in RMSE of 56.6% relative to the classical hydraulic approach. An analysis of the importance of input features by permutation importance and SHAP methods was carried out, confirming the dominant influence of oil flow rate and its viscosity, which makes it possible to purposefully optimize data collection and model tuning. A scenario for the practical application of the model for operational leak detection and optimization of pumping modes is considered, providing a reduction in the number of false alarms by 15–20% and energy savings of 2–3% without the need to modernize the sensor infrastructure. The limitations of the study (the limited volume of initial data and the synthetic nature of part of the sample) and directions for further work (including validation on real operational data and integration with industrial control systems) are discussed.

For citation

Zaripov R.R. (2026) Neyrosetevaya model' prognozirovaniya gidravlicheskih poter' v magistral'nykh nefteprovodakh na osnove ekspluatatsionnykh dannyykh SCADA: ekonomicheskie aspekty [Neural Network Model for Predicting Hydraulic Losses in Trunk Oil Pipelines Based on SCADA Operational Data: Economic Aspects]. *Ekonomika: vchera, segodnya, zavtra* [Economics: Yesterday, Today and Tomorrow], 16 (6A), pp. 863-876. DOI: 10.34670/AR.2026.67.43.079

Keywords

Trunk oil pipeline, hydraulic losses, predictive diagnostics, SCADA monitoring, machine learning, Random Forest, XGBoost, explainable artificial intelligence.

References

1. Aliev G.G., Mikhailov V.V. et al. Truboprovodny transport nefti. Moscow: Nedra, 2018. 368 p.
2. Tumaev A.K., Dontsov V.V. Gidravlika i gidropnevmoprivod. Moscow: Bauman MSTU Publ., 2019. 256 p.
3. Korolchenko D.A., Dyumina A.V. Primenenie neironnykh setei v zadachakh prognozirovaniia tekhnologicheskikh parametrov truboprovodnogo transporta nefti // Neftegazovoe delo. 2022. Vol. 20, No. 4. Pp. 89-97.
4. Lunev S.V., Starodubtsev M.A. Sravnenie algoritmov gradientnogo bustinga dlia prognozirovaniia davleniia v sistemakh magistralnykh nefteprovodov // Neftianoe khoziaistvo. 2023. No. 11. Pp. 118-123.
5. Goodfellow I., Bengio Y., Courville A. Deep Learning. Cambridge, MA: MIT Press, 2016. 800 p.
6. RD 39-30-139-79. Metodika teplovogo i gidravlicheskogo rascheta magistralnykh truboprovodov. Moscow: Minneftekhimprom, 1979. 89 p.
7. Chernikov V.I., Skorikov A.M. Gidravlicheski raschet neizotermicheskikh nefteprovodov // Izvestiia vuzov. Neft i gaz. 2020. Pp. 215-221.
8. Joseph K., Sharma A.K., Van Staden R. Leak and burst detection using SCADA and machine learning // Water. 2024. Vol. 16, No. 14. P. 1935.
9. Ahmed S., Rahman M., Khan M.A. Explainable AI for pipeline hydraulic parameter prediction using SHAP // J. Pipeline Syst. Eng. Pract. 2023. Vol. 14, No. 3. P. 04023020.

10. Petrov I.A., Vasilev K.D., Sidorov A.M. Sravnitelnyi analiz algoritmov mashinnogo obucheniia dlia diagnostiki truboprovodnykh sistem// Problemy sbora, podgotovki i transporta nefi i nefteproduktov. 2024. No. 2. Pp. 45-53.
11. Ismailov R.R., Kovalev D.S. Snizhenie lozhnykh trevog v sistemakh obnaruzheniia utechki nefteprovodov // Avtomatizatsiia, telemekhanizatsiia i sviaz v nefianoii promyshlennosti. 2024. No. 4. Pp. 28-34.