

УДК 622.6

DOI: 10.34670/AR.2026.64.88.078

Экономические аспекты разработки цифрового двойника магистрального нефтепровода с адаптивной калибровкой параметров потока

Мнацаканян Ваге Нелсонович

Бакалавр,
Российский государственный университет
нефти и газа (национальный исследовательский
университет) им. И.М. Губкина,
119991, Российская Федерация, Москва, Ленинский просп., 65;
e-mail: thebestvagr@gmail.com

Аннотация

В статье рассматриваются экономические аспекты построения прототипа цифрового двойника магистрального нефтепровода, интегрирующего одномерную гидродинамическую модель потока с двухуровневым адаптивным слоем машинного обучения для калибровки параметров, что позволяет повысить точность прогнозирования технологических параметров и снизить эксплуатационные издержки. Разработана архитектура, объединяющая физически обоснованную модель на основе уравнений Навье–Стокса в одномерной постановке, алгоритм градиентного бустинга (CatBoost) для коррекции глобальных расхождений и остаточную нейронную сеть (FFNN) для компенсации локальных нелинейностей, что обеспечивает адаптацию модели к изменяющимся условиям транспортировки без необходимости повторной настройки параметров. Ввиду ограниченного доступа к архивным SCADA-данным использование синтетического набора данных, сформированного в среде MATLAB/Simulink на основе паспортных характеристик реальных объектов, является общепринятой практикой для первичной валидации цифровых двойников, позволяющей оценить потенциал модели до внедрения на реальных объектах. Проведено сравнение с baseline-моделями (физическая модель, CatBoost, FFNN) и статистическая валидация методом 5-fold кросс-валидации. Гибридная модель снижает MAPE прогнозирования давления с 8,2% у физической модели до 2,1%, температуры – до 1,4%, расхода – до 0,8%; смоделированная утечка объёмом 0,6% от номинального расхода обнаруживается за 4,2 мин при точности локализации 2,0 км, а оптимизация режима работы перекачивающих станций обеспечивает снижение энергопотребления на 12–14%. Время инференса гибридной модели составляет 1,8 с, что соответствует требованиям реального времени для цикла сбора данных SCADA и позволяет интегрировать модель в существующие системы управления. Гибридный подход повышает точность прогнозирования, позволяет выявлять утечки и поддерживает оптимизацию режима перекачки, что в совокупности даёт значительный экономический эффект за счёт снижения потерь, сокращения аварийных простоев и оптимизации энергозатрат. Результаты свидетельствуют о перспективности гибридного подхода для интеграции в SCADA/АСУ ТП магистральных нефтепроводов и о его применимости для управления сложными технологическими процессами в нефтегазовой отрасли.

Для цитирования в научных исследованиях

Мнацаканян В.Н. Экономические аспекты разработки цифрового двойника магистрального нефтепровода с адаптивной калибровкой параметров потока // Экономика: вчера, сегодня, завтра. 2026. Том 16. № 6А. С. 849-862. DOI: 10.34670/AR.2026.64.88.078

Ключевые слова

Цифровой двойник, магистральный нефтепровод, машинное обучение, адаптивная калибровка, гидродинамическое моделирование, градиентный бустинг, нейронная сеть, обнаружение утечки, энергоэффективность.

Введение

Цифровая трансформация нефтегазовой отрасли сопровождается активным внедрением интеллектуальных методов анализа данных и моделирования сложных технических систем. Одним из ключевых направлений является концепция цифрового двойника, предполагающая создание виртуального представления физического объекта, функционирующего в тесной связи с реальным процессом и способного адаптироваться к изменениям эксплуатационных условий [Bárkányi, Chovan, Nemeth, Abonyi, 2021].

Цифровые двойники служат высокоэффективным инструментом обеспечения промышленной безопасности, повышения энергетической эффективности и совершенствования оперативного управления магистральным трубопроводным транспортом. Сложность таких систем, обусловленная их значительной протяжённостью, разнообразием рельефа трассы, динамикой температурных режимов и вариативностью физико-химических свойств нефти, существенно ограничивает прогностические возможности традиционных математических моделей. Применение фундаментальных уравнений гидродинамики и теплопроводности часто затруднено из-за накопления ошибок дискретизации, неопределённости граничных условий и изменения гидравлического сопротивления. Поэтому внедрение методов машинного обучения для адаптивной калибровки параметров модели является необходимым условием повышения достоверности имитационного моделирования [Aljameel et al., 2022].

Целью данной работы является разработка гибридной архитектуры прототипа цифрового двойника магистрального нефтепровода, объединяющей базовую физическую модель потока и двухуровневый интеллектуальный слой коррекции параметров, а также комплексная оценка её эффективности в сравнении с альтернативными подходами на задачах обнаружения утечек и оптимизации режимов перекачки.

Научная новизна работы заключается в разработке комплексного подхода к совершенствованию цифровых двойников магистральных трубопроводов. Предложена формализованная аддитивная декомпозиция ошибки цифрового двойника на глобальную параметрическую и локальную пространственно-структурную компоненты, обеспечиваемая последовательным применением моделей CatBoost и FFNN. Разработан остаточный индикатор деградации трубопровода, позволяющий интерпретировать пространственную структуру ошибок как диагностический признак асфальтосмолопарафиновых отложений (АСПО) и утечек. Реализован алгоритм адаптивной онлайн-перекалибровки параметров модели на скользящем временном окне 24 часа с шагом 15 минут, что существенно повышает прогностическую точность в реальных условиях.

Концепция цифрового двойника (Digital Twin, DT), введённая M. Grieves и J. Vickers,

определяет его как виртуальное представление физического объекта, способное имитировать поведение в реальном времени [Grieves, Vickers, 2016]. В нефтегазовой отрасли цифровые двойники применяются на всех этапах жизненного цикла. В трубопроводном транспорте исследования сосредоточены на гидродинамическом моделировании нестационарных режимов, прогнозировании технического состояния и обнаружении утечек.

Значительный вклад внесли Woldeyohannes и Majid [Woldeyohannes, Majid, 2020], разработавшие динамические модели газопроводов. Для оценки коррозии эффективно применяются ансамблевые методы машинного обучения. В задачах обнаружения утечек перспективны подходы на основе градиентного бустинга [Hassan, Azad, Mahmoud, 2023; Liu et al., 2023].

Российские авторы также активно развивают тему. Быкова и соавторы [Быкова, Ким, Гаджиалиев и др., 2020] подчёркивают необходимость интеграции физических моделей с данными SCADA. Денисламов и соавторы [Денисламов, Халилова, Стромов, 2021] анализируют влияние температуры на работу трубопроводов с АСПО.

В существующих работах сохраняются нерешённые проблемы: доминирование либо физических моделей, либо моделей машинного обучения типа «чёрный ящик», недостаток гибридных архитектур и систематического сравнения с базовыми подходами, на устранение чего направлена настоящая работа.

Материалы и методы исследования

Для апробации предложенного подхода использован синтетический набор данных, сформированный в MATLAB/Simulink на основе параметров реального типового участка магистрального нефтепровода. Применение синтетических данных является обоснованным шагом для первичной валидации в условиях ограниченного доступа к оперативным архивам SCADA.

Параметры моделируемого участка магистрального нефтепровода: протяжённость 500 км, внутренний диаметр 720 мм, толщина стенки 10 мм, материал – сталь 17Г1С. Участок оснащён двумя перекачивающими станциями (ПС-1 в начале и ПС-2 на 250 км) и шестью промежуточными пунктами измерения давления и температуры.

Параметры потока: начальная температура 50 °С, номинальный расход 850 м³/ч, плотность нефти 870 кг/м³ (при 20 °С), кинематическая вязкость $15 \cdot 10^{-6}$ м²/с (при 20 °С).

Общая продолжительность моделирования составила 365 суток с шагом 1 минута, что позволило сформировать массив из 525 600 записей. Входные признаки включают координату сечения X (км), давление P (МПа), температуру T (°С), расход Q (м³/ч), плотность, вязкость, температуру грунта T_{gr} (°С) и угол наклона трассы. Целевыми переменными являются отклонения модельных значений от измеренных. Данные разделены на обучающую и тестовую выборки в соотношении 80/20 с сохранением временной последовательности. Для кросс-валидации использован метод 5-fold с временным разбиением.

Для описания неустановившегося течения несжимаемой жидкости в трубопроводе применяется система уравнений Навье–Стокса в одномерной постановке, включающая уравнение неразрывности и уравнение движения:

$$\begin{cases} \frac{\partial \rho}{\partial t} + \frac{\partial(\rho v)}{\partial x} = 0 \\ \rho \left(\frac{\partial v}{\partial t} + v \frac{\partial v}{\partial x} \right) = -\frac{\partial p}{\partial x} - \rho g \sin \alpha - \frac{\lambda \rho v |v|}{2D} \end{cases} \quad (1)$$

где ρ – плотность нефти, кг/м³; t – время, с; x – пространственная координата вдоль оси трубопровода, км; α – угол наклона трассы к горизонту, рад; v – скорость потока, м/с; p – давление, Па; D – внутренний диаметр трубопровода, м; g – ускорение свободного падения, м/с²; λ – коэффициент гидравлического сопротивления.

Касательное напряжение на стенке τ_w определяется через коэффициент гидравлического сопротивления λ (формула Дарси–Вейсбаха):

$$\tau_w = \frac{\lambda \rho v |v|}{8} \quad (2)$$

Для турбулентного режима течения ($Re > 4000$) коэффициент λ рассчитывается по корреляции Черчилла:

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

где Re – число Рейнольдса $Re = \frac{vD}{\nu}$, $A = \left[-2,457 \ln \left(\frac{1}{\left(\frac{7}{Re} \right)^{0,9} + 0,27 \frac{k_s}{D}} \right) \right]^{16}$, $B = \left(\frac{37530}{Re} \right)^{16}$, k_s –

эквивалентная шероховатость стенки, м.

Распределение температуры вдоль трассы описывается уравнением энергии с учётом теплообмена с окружающей средой:

$$\rho c_p v \frac{dT}{dx} = -\frac{4k_{eff}}{D} (T - T_{gr}) + \frac{\lambda \rho v^3}{2D}, \quad (4)$$

где c_p – удельная теплоёмкость нефти, Дж/(кг·°C);

k_{eff} – эффективный коэффициент теплопередачи через стенку трубы и изоляцию, Вт/(м²·°C);

T_{gr} – температура грунта на глубине залегания трубопровода, °C.

Базовая физическая модель (1) содержит ряд параметров, подверженных вариативности в процессе эксплуатации: шероховатость стенки k_s , эффективный коэффициент теплопередачи k_{eff} , а также вязкость μ и плотность нефти ρ , зависящие от температуры и состава. Накопление ошибок дискретизации, образование асфальтосмолопарафиновых отложений (АСПО) на внутренней поверхности труб и неточности задания профиля трассы приводят к существенному расхождению между расчётными и измеренными значениями давления и температуры. Относительная ошибка модели без калибровки достигает 8–12 % на удалённых участках трассы.

Предложенная архитектура прототипа цифрового двойника включает три функциональных уровня: физический, модельный и интеллектуальный (рис. 1). Физический уровень представляет собой реальный нефтепровод как объект контроля, оснащённый системой датчиков (манометры, термопреобразователи, расходомеры, плотномеры) и исполнительными механизмами (насосные агрегаты, задвижки). Модельный уровень реализует численное решение системы уравнений (1) методом конечных разностей на адаптивной пространственной сетке с шагом 1 км по координате и 60 с по времени. Граничные условия задаются измеренными значениями давления и температуры на входе участка, а также расходом на выходе.




Рисунок 1 - Архитектура цифрового двойника магистрального нефтепровода: интеграция физической модели и двухуровневого слоя машинного обучения

Интеллектуальный уровень содержит модуль машинного обучения, который по остаточным отклонениям:

$$\delta P_i = P_{meas.i} - P_{model.i} \quad (5)$$

$$\delta T_i = T_{meas.i} - T_{model.i} \quad (6)$$

В контрольных сечениях корректирует калибровочные параметры модели: эффективную шероховатость k_s , эффективный коэффициент теплопередачи k_{eff} и поправку вязкости $\Delta\mu$.

Задача калибровки формулируется как оптимизационная: требуется найти вектор корректирующих параметров $\theta = (k_s, k_{eff}, \Delta\mu)$, минимизирующий функционал среднеквадратичной ошибки между измеренными и модельными значениями давления и температуры в M контрольных точках:

$$J(\theta) = \frac{1}{M} \sum_{i=1}^M \left[\alpha_P (P_{meas.i} - P_{model.i}(\theta))^2 + (1 - \alpha_P) (T_{meas.i} - T_{model.i}(\theta))^2 \right] \quad (7)$$

Обучение производится в режиме онлайн: каждые 15 мин формируется новый обучающий пример из актуальных телеметрических данных, и модель дообучается со скоростью обучения $\eta = 0,03$ на подвыборке последних $N_{win} = 96$ наблюдений (окно 24 ч). Глубина деревьев $d = 6$, количество итераций $K = 500$.

Для учёта нелинейных пространственных эффектов в зонах сосредоточенных аномалий (АСПО, локальные деформации трассы) к градиентному бустингу добавлен полносвязный слой (Feed-Forward Neural Network, FFNN) с архитектурой $7 \rightarrow 32 \rightarrow 16 \rightarrow 3$ и функцией активации Swish:

$$\sigma(z) = z \cdot \text{sigmoid}(\beta z) = \frac{z}{1 + e^{-\beta z}}, \quad (8)$$

где $\beta = 1,0$ – обучаемый параметр.

Выходной слой предсказывает остаточные поправки ΔP^{NN} , ΔT^{NN} , которые суммируются с выходами базовой модели и бустинга:

$$\hat{P}_i = P_{model.i} + \Delta P_i^{GB} \quad (9)$$

$$\hat{T}_i = T_{model.i} + \Delta T_i^{GB} \quad (10)$$

Итоговая функция потерь включает MSE-член и L₂-регуляризацию:

$$L = \frac{1}{M} \sum_{i=1}^M [(\hat{P}_i - P_{meas.i})^2 + (\hat{T}_i - T_{meas.i})^2] + \gamma \|w\|_2^2, \quad (11)$$

где w – веса нейронной сети; $\gamma = 10^{-4}$ – коэффициент регуляризации. Основная метрика качества – средняя абсолютная процентная ошибка (MAPE):

$$MAPE = \frac{100\%}{M} \sum_{i=1}^M \left| \frac{y_{meas.i} - \hat{y}_i}{y_{meas.i}} \right| \quad (12)$$

Дополнительные метрики: RMSE (среднеквадратичная ошибка) и R² (коэффициент детерминации).

Для объективной оценки эффективности предложенного подхода проведено сравнение с тремя baseline-моделями: чисто физической гидравлической моделью, CatBoost без физической компоненты и FFNN без физической компоненты. Статистическая значимость различий проверена методом 5-fold кросс-валидации с расчётом 95%-ных доверительных интервалов. Дополнительно выполнен анализ чувствительности к уровню шума датчиков и ablation study для оценки вклада каждого компонента архитектуры.

Результаты и обсуждение

Выбор гиперпараметров ML-моделей обоснован серией вычислительных экспериментов. Алгоритм CatBoost выбран благодаря устойчивости к аддитивному шуму в признаках и низкой чувствительности к масштабу входных данных по сравнению с XGBoost и LightGBM. Глубина деревьев $d = 6$ определена по критерию минимизации валидационного RMSE с ранней остановкой обучения.

Архитектура FFNN 7→32→16→3 выбрана по минимальному значению валидационного loss среди нескольких конфигураций (табл. 1). Она обеспечивает наилучшее соотношение точности и вычислительных затрат.

Таблица 1 - Сравнение архитектур FFNN (validation MSE, МПаЗ)

Архитектура	Val MSE	Время обучения, с	Параметров
7→16→8→3	0,0045	4,2	387
7→32→16→3	0,00395	8,0	1 219
7→64→32→3	0,00388	14,5	4 163
7→32→16→8→3	0,0041	10,3	1 627

Функция активации Swish показала на 4,1 % меньший MSE по сравнению с ReLU на валидационной выборке при аналогичной архитектуре. Swish обеспечивает гладкую нелинейность и лучшую дифференцируемость в нуле, что критично для остаточной коррекции.

Learning rate $\eta = 0,03$ определён по learning curve с использованием cosine annealing scheduler. При данном значении достигается стабильная сходимость за 500 итераций без расхождения train/val loss.




Рисунок 2 - Обоснование выбора гиперпараметров ML-моделей: (а) CatBoost learning curves (depth=6, $\eta = 0,03$); (б) сравнение функций активации FFNN

По данным анализа feature importance алгоритма CatBoost доминирующее влияние оказывают остаточные ошибки предыдущих итераций ($\delta P - 28,5\%$, $\delta T - 22,3\%$) и координата сечения x ($18,7\%$), что подтверждает физическую обоснованность модели (рис. 3).




Рисунок 3 - Важность признаков в модели CatBoost (уровень 1: глобальная коррекция параметров) по методу PredictionValuesChange

Численное моделирование проведено на тестовом участке магистрального нефтепровода ($L = 500$ км, $D = 720$ мм, две ПС). На рисунке 4 представлены результаты сравнения MAPE прогнозирования давления для всех моделей с указанием стандартного отклонения σ .




Рисунок 4 - Сравнение точности прогнозирования (MAPE ± σ) по baseline-моделям на тестовом участке 500 км (результаты 5-fold кросс-валидации)

Базовая физическая модель без калибровки демонстрирует нарастающую ошибку прогноза давления от $1,8 \pm 0,2$ % на первых 50 км до $8,2 \pm 0,4$ % на расстоянии 500 км вследствие аккумуляции погрешностей параметров. Внедрение гибридного подхода снижает MAPE до $0,9 \pm 0,1$ % на начальном участке и $2,1 \pm 0,2$ % на конечном, обеспечивая равномерную точность на всей трассе.

В таблице 2 представлены полные метрики точности для ключевых параметров по результатам 5-fold кросс-валидации (среднее ± стандартное отклонение).

Таблица 2 - Сравнение метрик точности моделей (среднее ± σ, 5-fold CV)

Параметр	Модель	MAPE, %	RMSE	R2
Давление P	Физическая модель	$8,2 \pm 0,4$	$0,42 \pm 0,02$ МПа	$0,84 \pm 0,03$
Давление P	CatBoost (только ML)	$3,4 \pm 0,3$	$0,18 \pm 0,02$ МПа	$0,94 \pm 0,02$
Давление P	FFNN (только ML)	$3,1 \pm 0,25$	$0,16 \pm 0,01$ МПа	$0,95 \pm 0,02$
Давление P	Physics + CatBoost	$2,8 \pm 0,2$	$0,14 \pm 0,01$ МПа	$0,96 \pm 0,01$
Давление P	Physics + CatBoost + FFNN (предл.)	$2,1 \pm 0,2$	$0,11 \pm 0,01$ МПа	$0,98 \pm 0,01$
Температура T	Физическая модель	$5,6 \pm 0,3$	$3,8 \pm 0,2$ °C	$0,79 \pm 0,03$
Температура T	CatBoost (только ML)	$2,2 \pm 0,2$	$1,4 \pm 0,1$ °C	$0,93 \pm 0,02$
Температура T	FFNN (только ML)	$1,9 \pm 0,15$	$1,2 \pm 0,1$ °C	$0,95 \pm 0,02$
Температура T	Physics + CatBoost	$1,7 \pm 0,15$	$1,1 \pm 0,1$ °C	$0,96 \pm 0,01$
Температура T	Physics + CatBoost + FFNN (предл.)	$1,4 \pm 0,15$	$0,9 \pm 0,1$ °C	$0,97 \pm 0,01$
Расход Q	Физическая модель	$3,1 \pm 0,2$	$26,4 \pm 1,5$ м³/ч	$0,91 \pm 0,02$
Расход Q	CatBoost (только ML)	$1,5 \pm 0,15$	$12,8 \pm 1,0$ м³/ч	$0,97 \pm 0,01$
Расход Q	FFNN (только ML)	$1,3 \pm 0,1$	$11,1 \pm 0,8$ м³/ч	$0,98 \pm 0,01$

Параметр	Модель	MAPE, %	RMSE	R2
Расход Q	Physics + CatBoost	$1,1 \pm 0,1$	$9,4 \pm 0,8 \text{ м}^3/\text{ч}$	$0,98 \pm 0,01$
Расход Q	Physics + CatBoost + FFNN (предл.)	$0,8 \pm 0,1$	$6,8 \pm 0,6 \text{ м}^3/\text{ч}$	$0,99 \pm 0,01$

Результаты демонстрируют, что предложенная гибридная архитектура статистически достоверно превосходит все baseline-модели ($p < 0,01$ по t-критерию Стьюдента). Использование только физической модели даёт наихудший результат, добавление CatBoost обеспечивает основной прирост точности, а включение остаточной FFNN даёт дополнительное улучшение.

На рисунке 5 представлены результаты 5-fold кросс-валидации, подтверждающие стабильность предложенного подхода. Доверительный интервал 95 % для MAPE давления составляет $[1,7; 2,5]$ %, а межквартильный размах (IQR) гибридной модели равен 0,3 % (против 0,7 % у физической модели).




Рисунок 5 - Результаты 5-fold кросс-валидации: распределение MAPE давления по моделям и фолдам (ДИ 95 % для гибридной модели, %)

Для оценки робастности модели проведён анализ чувствительности к уровню аддитивного белого шума в измерениях.

Таблица 3 - Зависимость MAPE от уровня шума датчиков (sensitivity analysis)

Уровень шума, %	MAPE давления, %	MAPE температуры, %	Время обнаружения утечки, мин
0	$2,1 \pm 0,2$	$1,4 \pm 0,15$	$4,2 \pm 0,6$
1	$2,4 \pm 0,2$	$1,6 \pm 0,15$	$4,8 \pm 0,7$
3	$3,0 \pm 0,25$	$2,1 \pm 0,2$	$6,5 \pm 0,9$
5	$4,7 \pm 0,4$	$3,2 \pm 0,3$	$9,1 \pm 1,2$

Результаты (табл. 3, рис. 6) показывают, что при шуме 1 % (типичный уровень для промышленных датчиков) MAPE давления возрастает с 2,1 % до 2,4 %, а при шуме 3 % – до 3,0 %, что остаётся в пределах допустимого требования 3 % для задач оперативного контроля.




Рисунок 6 - Зависимость точности прогнозирования и времени обнаружения утечки от уровня шума датчиков (sensitivity analysis); рабочий диапазон – шум $\leq 3\%$

Для оценки чувствительности прототипа к локальным аномалиям смоделирована сценарная утечка объёмом $q_{leak} = 5 \text{ м}^3/\text{ч}$ (0,6 % от номинального расхода) на расстоянии $x_{leak} = 300 \text{ км}$ от начала трассы. Модель зафиксировала падение давления на выходе на $\Delta P = 0,45 \text{ МПа}$ и увеличение расхода на входе на $\Delta Q = 28 \text{ м}^3/\text{ч}$ (рис. 7). Время обнаружения составило $4,2 \pm 0,6$ мин при локализации дефекта с точностью $2,0 \pm 0,4 \text{ км}$, что удовлетворяет требованиям нормативных документов по промышленной безопасности.




Рисунок 7 - Результаты моделирования обнаружения утечки ($q = 5 \text{ м}^3/\text{ч}$, 0,6 % от номинала): изменение давления на выходе и расхода на входе при дефекте на 300 км

Прототип цифрового двойника использован для оптимизации режима работы перекачивающих станций по критерию минимума суммарного энергопотребления при

заданном графике отгрузки нефти. Сравнивались четыре сценария (таблица 4, рисунок 8).

Таблица 4 - Сравнение энергопотребления при различных режимах перекачки

Сценарий	Расход, м³/ч	Энергопотребление, кВт·ч/сут	Отклонение от базового, %
Базовый режим	850	1250	—
Режим 1 (–10 % Q)	765	1120	–10,4




Рисунок 8 - Сравнение суточного энергопотребления при различных сценариях работы перекачивающих станций

Режим, найденный с помощью цифрового двойника, обеспечивает снижение энергозатрат на 12–14 % ($\Delta E \approx 170$ кВт·ч/сут) при сохранении планового объёма перекачки за счёт сглаживания пиковых нагрузок на ПС-2 и перераспределения напора между станциями.

Важным аспектом внедрения прототипа в АСУ ТП является оценка вычислительных затрат (таблица 5). Время инференса гибридной модели (1,8 с) соответствует требованиям real-time для цикла сбора данных SCADA (60 с), что подтверждает техническую реализуемость внедрения.

Таблица 5 - Вычислительные характеристики моделей (Intel Core i7-12700H / 16 GB RAM)

Параметр	Физ. модель	CatBoost	FFNN	Гибрид (предл.)
Время инференса, с	0,3	0,8	0,5	1,8
RAM, МБ	45	85	60	220
Время обучения (1 итерация), с	—	2,5	8,0	12,0

Предложенная гибридная архитектура прототипа цифрового двойника демонстрирует статистически достоверное превосходство над классической физической моделью и отдельными ML-подходами (табл. 2). Ключевым фактором успеха является способность CatBoost адаптироваться к постепенным изменениям гидравлического сопротивления, вызванным отложениями АСПО, а также способность нейронной сети улавливать локальные нелинейности, не описываемые одномерной моделью.

Сравнение с результатами аналогичных исследований подтверждает

конкурентоспособность подхода. В отличие от методов, требующих специализированной акустической телеметрии, предложенная модель работает со стандартными SCADA-измерениями давления и расхода. Гибридный подход сочетает физическую интерпретируемость с возможностью объяснения решений (explainable AI) и экстраполяционной устойчивостью. Введённый остаточный индикатор деградации позволяет получать дополнительную диагностическую информацию о состоянии трубопровода.

Анализ чувствительности (табл. 3) подтверждает работоспособность модели при уровне шума датчиков до 3 %, что соответствует типичным промышленным условиям.

Ограничения работы. Основным ограничением является использование синтетических данных. Хотя параметры калиброваны по паспортным характеристикам реальных объектов, окончательная валидация требует апробации на архивных SCADA-данных. Кроме того, одномерная постановка не учитывает радиальные градиенты, модель ориентирована на однофазный ньютоновский поток, а устойчивость при отказе датчиков и смешанных потоках требует дополнительных исследований.

Перспективные направления включают апробацию на реальных данных ПАО «Транснефть», интеграцию Physics-Informed Neural Networks (PINNs), байесовские подходы к оценке неопределённости, применение reinforcement learning для оптимизации режимов и расширение модели на многофазные потоки.

Предложенный подход может быть интегрирован в существующие SCADA/АСУ ТП без замены оборудования. Он позволяет решать задачи раннего обнаружения утечек, оценки технического состояния, оптимизации энергопотребления и поддержки принятия решений диспетчером.

Заключение

Разработана гибридная архитектура прототипа цифрового двойника магистрального нефтепровода, сочетающая одномерную гидродинамическую модель, CatBoost и остаточную нейронную сеть FFNN с иерархической онлайн-калибровкой параметров. Проведено сравнение с baseline-моделями и статистическая валидация методом 5-fold кросс-валидации. Гибридный подход обеспечивает существенно более высокую точность прогнозирования давления и температуры. Прототип демонстрирует возможность своевременного обнаружения утечек малого объёма и сохранение работоспособности при типичном уровне шума датчиков. Использование цифрового двойника позволяет снизить энергопотребление перекачивающих станций при сохранении планового графика отгрузки. Вычислительные характеристики модели (время инференса и потребление памяти) подтверждают возможность её встраивания в промышленные системы управления. Предложенный подход рекомендуется для внедрения в АСУ ТП магистральных нефтепроводов в качестве элемента системы промышленной безопасности и энергоменеджмента.

Библиография

1. Bárkányi Á., Chovan T., Nemeth S., Abonyi J. Modelling for digital twins, potential role of surrogate models // Processes. 2021. Vol. 9, № 3. P. 476. DOI: 10.3390/pr9030476.
2. Aljameel S.S. et al. An anomaly detection model for oil and gas pipelines using machine learning // Applied Sciences. 2022. Vol. 12, № 8. P. 4009. DOI: 10.3390/ap 12084009.
3. Grieves M., Vickers J. Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems // Transdisciplinary Perspectives on Complex Systems. Springer, 2016. P. 85-113. DOI: 10.1007/978-3-319-38756-7_4.

4. Woldeyohannes A.D., Majid M.A.A. Dynamic simulation of large-scale pipeline networks using ode solvers // Journal of Pipeline Systems Engineering and Practice. 2020. Vol. 11, № 2. P. 04020005. DOI: 10.1061/(ASCE)PS.1949-1204.0000448.
5. Amjed Hassan, Madhar Sahib Azad, Mohamed Mahmoud. An analysis of nitrogen EOR screening criteria parameters based on the up-to-date review // Journal of Petroleum Science and Engineering. 2023. Vol. 220. P. 111123. DOI: 10.1016/j.petrol.2022.111123.
6. Xixi Liu, Xuguang Chen, Jiakang Wei, Shuai Jin, Xingzheng Gao, Guodong Sun a, Jiahao Yan, Qingqing Lu. A leak sensing method for offshore oil pipeline using acoustic emission signals and machine learning // Ocean Engineering. 2023. Vol. 284. P. 115220. DOI: 10.1016/j.oceaneng.2023.115220.
7. Быкова В.Н., Ким Е., Гаджиалиев М.Р. и др. Применение цифрового двойника в нефтегазовой отрасли // Актуальные проблемы нефти и газа. 2020. № 1(28). С. 1-11. DOI: 10.29222/ipng.2078-5712.2020-28.art8.
8. Денисламов И.З., Халилова Г.А., Стромов К.А. Анализ влияния степени подогрева нефти на режим работы трубопровода, осложнённого асфальтосмолопарафиновыми отложениями // Нефтегазовое дело. 2021. Т. 19, № 1. С. 92-100. DOI: 10.17122/ngdelo-2021-1-92-100.

Economic Aspects of Developing a Digital Twin of a Trunk Oil Pipeline with Adaptive Calibration of Flow Parameters

Vage N. Mnatsakanyan

Bachelor,
National University of Oil and Gas "Gubkin University",
119991, 65, bld. 1, Leninskiy ave., Moscow, Russian Federation;
e-mail: thebestvagr@gmail.com

Abstract

The article examines the economic aspects of building a prototype of a digital twin of a trunk oil pipeline, integrating a one-dimensional hydrodynamic flow model with a two-level adaptive machine learning layer for parameter calibration, which makes it possible to increase the accuracy of forecasting technological parameters and reduce operational costs. An architecture has been developed that combines a physically grounded model based on the Navier–Stokes equations in a one-dimensional formulation, a gradient boosting algorithm (CatBoost) for correcting global discrepancies, and a residual feedforward neural network (FFNN) for compensating local nonlinearities, which ensures the adaptation of the model to changing transportation conditions without the need for repeated parameter tuning. Due to limited access to archival SCADA data, the use of a synthetic dataset generated in the MATLAB/Simulink environment based on the passport characteristics of real objects is a generally accepted practice for the initial validation of digital twins, allowing the potential of the model to be assessed before implementation at real facilities. A comparison with baseline models (physical model, CatBoost, FFNN) and statistical validation using the 5-fold cross-validation method have been carried out. The hybrid model reduces the MAPE of pressure forecasting from 8.2% for the physical model to 2.1%, temperature – to 1.4%, flow rate – to 0.8%; a simulated leak of 0.6% of the nominal flow rate is detected in 4.2 minutes with a localization accuracy of 2.0 km, and optimization of the operating mode of pumping stations ensures a reduction in energy consumption by 12–14%. The inference time of the hybrid model is 1.8 s, which meets the real-time requirements for the SCADA data acquisition cycle and allows the model to be integrated into existing control systems. The hybrid approach increases the accuracy of forecasting, makes it possible to detect leaks, and supports the optimization of the pumping mode,

which collectively provides a significant economic effect by reducing losses, reducing emergency downtime, and optimizing energy costs. The results indicate the promising nature of the hybrid approach for integration into SCADA/APCS of trunk oil pipelines and its applicability for managing complex technological processes in the oil and gas industry.

For citation

Mnatsakanyan V.N. (2026) Ekonomicheskie aspekty razrabotki tsifrovogo dvoynika magistral'nogo nefteprovoda s adaptivnoy kalibrovkoy parametrov potoka [Economic Aspects of Developing a Digital Twin of a Trunk Oil Pipeline with Adaptive Calibration of Flow Parameters]. *Ekonomika: vchera, segodnya, zavtra* [Economics: Yesterday, Today and Tomorrow], 16 (6A), pp. 849-862. DOI: 10.34670/AR.2026.64.88.078

Keywords

Digital twin, trunk oil pipeline, machine learning, adaptive calibration, hydrodynamic modeling, gradient boosting, neural network, leak detection, energy efficiency.

References

1. Bárkányi Á., Chovan T., Nemeth S., Abonyi J. Modelling for digital twins, potential role of surrogate models // *Processes*. 2021. Vol. 9, No. 3. P. 476. DOI: 10.3390/pr9030476.
2. Aljameel S.S. et al. An anomaly detection model for oil and gas pipelines using machine learning // *Applied Sciences*. 2022. Vol. 12, No. 8. P. 4009. DOI: 10.3390/ap12084009.
3. Grieves M., Vickers J. Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems // *Transdisciplinary Perspectives on Complex Systems*. Springer, 2016. Pp. 85-113. DOI: 10.1007/978-3-319-38756-7_4.
4. Woldeyohannes A.D., Majid M.A.A. Dynamic simulation of large-scale pipeline networks using ode solvers // *Journal of Pipeline Systems Engineering and Practice*. 2020. Vol. 11, No. 2. P. 04020005. DOI: 10.1061/(ASCE)PS.1949-1204.0000448.
5. Amjed Hassan, Madhar Sahib Azad, Mohamed Mahmoud. An analysis of nitrogen EOR screening criteria parameters based on the up-to-date review // *Journal of Petroleum Science and Engineering*. 2023. Vol. 220. P. 111123. DOI: 10.1016/j.petrol.2022.111123.
6. Xixi Liu, Xuguang Chen, Jiakang Wei, Shuai Jin, Xingzheng Gao, Guodong Sun a, Jiahao Yan, Qingqing Lu. A leak sensing method for offshore oil pipeline using acoustic emission signals and machine learning // *Ocean Engineering*. 2023. Vol. 284. P. 115220. DOI: 10.1016/j.oceaneng.2023.115220.
7. Bykova V.N., Kim E., Gadzhialiev M.R., et al. Primenenie tsifrovogo dvoynika v neftegazovoi otras li // *Aktual'nye problemy nefti i gaza*. 2020. No. 1(28). Pp. 1-11. DOI: 10.29222/ipng.2078-5712.2020-28.art8.
8. Denislamov I.Z., Khalilova G.A., Stromov K.A. Analiz vliyaniya stepeni podogreva nefti na rezhim raboty truboprovoda, oslozhnennogo asfaltosmoloparafinovymi otlozheniyami // *Neftegazovoe delo*. 2021. Vol. 19, No. 1. Pp. 92-100. DOI: 10.17122/ngdelo-2021-1-92-100.