

УДК: 004.896

## Каскадная модель нейронной сети с физической поддержкой для предсказания потерь давления трехфазной смеси в трубопроводе

А. О. Шлыкова<sup>1,a</sup>, Ю. А. Шевченко<sup>1,2,b</sup>, С. В. Минин<sup>1,c</sup>,  
А. П. Королева<sup>1,d</sup>

<sup>1</sup>Научно-технологический университет «Сириус»,  
Россия, 354340, Федеральная территория «Сириус», Олимпийский пр., д. 1

<sup>2</sup>Институт прикладной математики ДВО РАН,  
Россия, 690041, г. Владивосток, ул. Радио, д. 7

E-mail: <sup>a</sup> shlykova.ao@talantiuspeh.ru, <sup>b</sup> shevchenko.yuriy.a@gmail.com, <sup>c</sup> minin.sv@talantiuspeh.ru,  
<sup>d</sup> koroleva.anp@talantiuspeh.ru

*Получено 13.10.2025, после доработки — 09.12.2025.  
Принято к публикации 22.12.2025.*

В работе представлена каскадная модель нейронной сети с физической поддержкой, предназначенная для прогнозирования перепада давления при трехфазном течении (нефть, газ, вода) в прямом участке трубы с различными углами наклона. Для преодоления ограничений существующих эмпирических корреляций и вычислительно затратных методов численного моделирования предложена архитектура, декомпозирующая задачу на три последовательные физически интерпретируемые подзадачи: регрессионное прогнозирование коэффициента удержания жидкости, классификация режима течения и непосредственный расчет градиента давления. Каждая подзадача решается отдельной полносвязной нейронной сетью, выход которой передается следующей модели в каскаде. Обучение и тестирование предложенной модели проведены на обширном синтетическом наборе данных ( $8 \cdot 10^7$  записей), сгенерированном с использованием полуэмпирической модели. Верификация выполнена на независимых экспериментальных данных. Проведен сравнительный анализ с единой полносвязной (не каскадной) нейронной сетью и исследована чувствительность моделей методами Соболя и Боргоново. Каскадная модель продемонстрировала превосходство по точности и обеспечила высокую интерпретируемость результатов за счет получения промежуточных физических параметров (коэффициента удержания жидкости, режима течения). Разработанная модель обладает низкой вычислительной сложностью, что позволяет использовать ее в системах реального времени и цифровых двойниках гидравлических систем нефтегазовой промышленности.

Ключевые слова: каскадная архитектура нейронной сети, многофазное течение, машинное обучение, поведение течения, регрессионная модель

Результаты получены при финансовой поддержке проекта, реализуемого в рамках государственной программы федеральной территории «Сириус» «Научно-технологическое развитие федеральной территории “Сириус”» (Соглашение № 18-03 от 10.09.2024).

UDC: 004.896

## Physics-assisted cascade neural network model for predicting pressure losses of a three-phase mixture in a pipeline

A. O. Shlykova<sup>1,a</sup>, Yu. A. Shevchenko<sup>1,2,b</sup>, S. V. Minin<sup>1,c</sup>, A. P. Koroleva<sup>1,d</sup>

<sup>1</sup>Sirius University of Science and Technology,  
1 Olimpijskij ave., Sirius federal territory, 354340, Russia

<sup>2</sup>Institute of Applied Mathematics FEB RAS,  
7 Radio st., Vladivostok, 690041, Russia

E-mail: <sup>a</sup> shlykova.ao@talantiuspeh.ru, <sup>b</sup> shevchenko.yuriy.a@gmail.com, <sup>c</sup> minin.sv@talantiuspeh.ru,  
<sup>d</sup> koroleva.anp@talantiuspeh.ru

*Received 13.10.2025, after completion – 09.12.2025.*

*Accepted for publication 22.12.2025.*

The paper presents a cascade model of a physically supported neural network designed to predict pressure drop in three-phase flow (oil, gas, water) in a pipe section with various angles of inclination. To overcome the constraints of existing empirical correlations and computation-intensive numerical modeling methods, we propose an architecture that decomposes the problem into three sequential physically interpretable subtasks: regression prediction of the fluid hold-up coefficient, fluid flow regime classification, and pressure gradient evaluation. Each subtask is solved by a separate fully connected neural network, the output of which is passed to the next model in the cascade. Training and testing of the proposed architecture was performed on an extensive synthetic dataset ( $8 \cdot 10^7$  records) generated using a semi-empirical model. Verification is performed on independent experimental data. A comparative analysis with a single fully connected (non-cascade) neural network is made, and the sensitivity of the models is examined using Sobol and Borgonovo methods. The cascade model demonstrates superior accuracy and ensures high interpretability of results by providing intermediate physical parameters (fluid hold-up coefficient, flow regime). The developed model has low computational complexity, which allows it to be used in real-time systems and digital twins of hydraulic systems in the oil and gas industry.

**Keywords:** physically assisted neural network, multiphase flow, machine learning, flow behavior, regression model

**Citation:** *Computer Research and Modeling*, 2026, vol. 18, no. 1, pp. 117–131 (Russian).

The results obtained with the financial support of the project within the framework of the state program of the federal territory “Sirius” “Scientific and technological development of the federal territory ‘Sirius’” (Agreement No. 18-03 of 10.09.2024).

## 1. Введение

Задачи оптимизации и предсказания характеристик течения многофазного потока в трубопроводе [Tariq et al., 2019; Orokou et al., 2020; Al-Rbeawi, 2019; Hou et al., 2019] возникают во многих областях промышленности. Например, при бурении нефтяных скважин [Evelle, Gerogiorgis, 2019], гидроразрыве пластов [Cui et al., 2020; Pei et al., 2019], очистке нефтяных или газовых скважин [Zhang et al., 2016] и т. п. Под многофазным потоком понимается направленное в одну сторону движение вещества, состоящего из двух или более несмешиваемых между собой компонентов, каждый из которых может пребывать в твердой, жидкой либо газообразной фазе. От корректного определения параметров таких потоков зависит эффективность проектирования и эксплуатации оборудования.

В этой работе рассматривается задача предсказания перепада давления в трубопроводе, возникающая при добыче и транспортировке нефти. Классическая постановка задачи определяется следующим образом. В подземном резервуаре находится смесь нефти и воды. Свойства скважины предполагают высокое давление и нередко высокую температуру внутри резервуара, из-за чего в жидкости присутствует определенное количество растворенного газа. Процесс добычи заключается в подъеме жидкости на поверхность по трубопроводу. В процессе транспортировки давление, оказываемое на жидкость, падает, и из жидкости высвобождается растворенный газ. Также из-за падения давления в трубе появляется водяной пар. Далее в процессе транспортировки смесь охлаждается из-за плотного контакта стенок трубопровода с землей, что дополнительно влияет на реологические свойства смеси.

Восходящее течение в вертикальной трубе достигается за счет создания разности давления на концах: избыточного в резервуаре, пониженного на поверхности. Причем разница должна быть больше потерь давления, возникающих в процессе течения. Общие потери давления имеют три составляющих: потери на трение, гравитационные и потери на ускорение. Гравитационные потери зависят от угла наклона трубы и плотности смеси. Потери на ускорение проявляются при больших скоростях, и в рамках рассматриваемой задачи ими можно пренебречь. Потери на трение обусловлены разностью скоростей движения фаз относительно друг друга и стенок трубы. Так, в зависимости от соотношения скоростей в трубе могут возникать различные режимы течения, которые главным образом могут повлиять на потери давления.

На данный момент все модели описания режимов течения являются эмпирическими либо полуэмпирическими [Bahrami et al., 2024]. Такие корреляции заложены в основу коммерческих симуляторов инженерного назначения (OLGA, LedaFlow, Prosper) и используются в промышленности для предсказания потерь давления мультифазных потоков с приемлемой для промышленности точностью. Корреляции основаны либо на экспериментальных данных, либо на данных, полученных посредством моделирования, с использованием уравнений гидродинамики.

Данные лабораторных экспериментов ограничены своим количеством [Feng et al., 2023; Pereyra et al., 2012; Hernandez et al., 2019]. Наиболее полный перечень источников экспериментальных данных [Hernandez et al., 2019] содержит 37 649 экспериментов, включающих как двухфазные, так и трехфазные потоки. Но этот источник доступен в виде перечня ссылок на публикации, в которых опубликованы результаты экспериментов. Непосредственные значения замеров чаще авторами не публикуются и могут быть доступны только по запросу. Опубликованные данные никак не стандартизованы, и приведение их к единому виду требует дополнительных трудозатрат. Наиболее полный общедоступный скомпилированный набор данных [Pereyra et al., 2012] содержит 9029 строк. Набор данных имеет малую вариативность характеристик рабочих жидкостей, диаметров трубы и углов наклона. Чаще всего рассматривается комбинация воздуха и воды, реже в качестве жидкости выступают керосин и Exxon D80, также называемый легкой нефтью. Однако качество экспериментов ставится под сомнение из-за несоответствия с другими аналогичными экспериментами [Kanin et al., 2019; Mandhane et al., 1974; Hernandez et al., 2019].

Другим источником экспериментальных данных являются замеры оборудования нефтедобывающих и нефтеперерабатывающих предприятий, например [Asheim, 1986]. Такие данные являются сопутствующими при нефтедобыче. Физические свойства флюида чаще фиксированы, а скорости подачи фаз далеки от критических. Такие данные не будут сбалансированными и пригодны только для верификации моделей.

Второй подход, компьютерное моделирование, не ограничивает физических параметров флюида и геометрии трубопровода. В компьютерной модели, как и в эксперименте, требуется рассматривать трубопровод протяженностью не менее  $10D$  ( $D$  — диаметр трубы) для стабилизации режима течения и внутреннего давления. Увеличение протяженностикратно увеличивает число ячеек вычислительной сетки. Расчеты уравнений гидродинамики на больших сетках требуют больших вычислительных ресурсов, поэтому не применимы для оперативного управления оборудованием в нефтедобывающей промышленности.

Позже наряду с эмпирическими моделями стали активно применяться регрессионные модели, где данные экспериментов и моделирования используются в качестве обучающего набора. В качестве моделей успешно применяют Random Forest [Sun et al., 2023; Frau et al., 2021], Support Vector Machine [Li et al., 2014; Trafalis et al., 2005], Gradient boosting [Bikmukhametov, Jäschke, 2019; Jiang et al., 2019], искусственные нейронные сети [Sun et al., 2023; Kanin et al., 2018; Frau et al., 2021; Jiang et al., 2019]. Модели показывают хороший результат, но авторы алгоритмов отмечают недостаток достоверных данных для обучающего и верификационного наборов.

В настоящей работе для прогнозирования перепада давления трехфазной смеси в трубопроводе используется каскадная модель нейронной сети, декомпозирующая задачу на три подзадачи: регрессионное прогнозирование коэффициента удержания жидкости (далее в тексте КУЖ), классификацию режима течения и расчет градиента давления. Для каждой подзадачи строится и обучается отдельная последовательная многослойная полносвязная нейронная сеть типа «перцептрон». Результат одной модели добавляется к вектору ее входных значений и передается следующей модели по цепочке. Такой подход сравнивается с классической полносвязной моделью без разбивки на каскады. Поскольку каждый этап каскадной модели представляет собой полносвязную нейронную сеть, а единая нейронная сеть также обладает полносвязной архитектурой, далее термином «полносвязная» будет обозначена классическая модель.

В отличие от полносвязной модели нейронной сети предлагаемая каскадная архитектура позволяет повысить точность предсказания без существенного повышения вычислительных затрат, увеличить прозрачность и интерпретируемость результатов. Архитектура позволяет использовать ее в системах реального времени. Прогнозы промежуточных моделей могут быть использованы для построения стандартных диаграмм режимов течения. Средняя погрешность предсказания каскадной моделью составляет менее 0,06% относительно эталонного значения. Для обученной нейронной сети проведен анализ чувствительности к изменению входных параметров, результат работы проверен на экспериментальных данных.

## 2. Постановка задачи

Рассматривается труба с круглым сечением без изгибов, внутренним диаметром  $d$  и площадью сечения  $S$ . Поток в трубе представляет собой смесь двух видов жидкостей с различной плотностью и вязкостью (вода и нефть) и газа; поток не имеет фракций твердого вещества, фазы не перемешиваются и химически не реагируют друг с другом. В задаче используется участок трубы, в котором жидкость преодолела точки газообразования, то есть в трубе уже присутствует газ. Смена фазы вещества не рассматривается.

Обозначения газа ( $g$ ), воды ( $w$ ), нефти ( $o$ ), жидкости ( $l$ ), смеси ( $m$ ) используются далее в тексте в виде подстрочных индексов для определения принадлежности параметра к нужной фазе. Жидкость ( $l$ ) является совокупностью  $w$  и  $o$ . Смесь ( $m$ ) =  $g + w + o$ .

Немаловажным параметром при определении перепада давления многофазного течения является КУЖ ( $h$ ,  $h_l$ ) — доля поперечного сечения трубы, занятая жидкостью, определяемая как  $h = \frac{S_l}{S}$ , где  $S_l$  — площадь сечения трубы, занятая жидкостью. Фактическое значение  $h$  зависит от многих факторов, и на сегодняшний день не существует точной физической модели для определения значения на основе параметров течения. Приближенную оценку без учета прилипания (проскальзывания) можно определить как

$$h_{\text{no-slip}} = \frac{q_l}{q_l + q_g}, \quad (1)$$

где  $q$  — объемный расход соответствующей фазы ( $\text{м}^3/\text{с}$ ).

При расчетах многофазного потока довольно часто используют уравнения однофазного потока, которые модифицируются с учетом наличия второй и третьей фаз. К таким уравнениям относятся выражения для скоростей и свойств флюидов смеси, в которых фигурируют весовые коэффициенты, представляющие собой массовые или объемные доли. Переменные и весовые коэффициенты выбирают с учетом прогнозируемого режима потока. Из-за различия своих плотностей и вязкостей фазы в трубе движутся с различной скоростью, что вызывает эффект проскальзывания на границе между фазами. Если бы не было проскальзывания между фазами, то и газ, и жидкость перемещались бы с одной скоростью. Из-за проскальзывания между фазами скорость жидкости обычно меньше скорости смеси, в то время как скорость газа значительно превышает скорость смеси.

Введем понятие поверхностной скорости  $V_s$  ( $\text{м}/\text{с}$ ) — скорость соответствующей фазы, если бы она была одна в трубе. На примере жидкости ее можно определить как  $V_{sl} = \frac{q_l}{S}$ . Стоит обратить внимание, что в знаменателе используется  $S$ , а не  $S_l$ . Объемный расход смеси можно определить как  $q_m = q_l + q_g$ . Из этого следует, что поверхностные скорости тоже являются суммой составляющих:  $V_{sm} = V_{sl} + V_{sg}$ .

В рамках этого исследования для обучения нейронной сети используется набор синтетических данных, полученных в рамках полуэмпирической модели [Beggs, Brill, 1973], которая была построена авторами на основе 584 экспериментальных замеров трехфазного течения при разных углах наклона труб. Поток представляет собой смесь трех фаз: газа, нефти и воды (рис. 1). Фазы считаются несмешивающимися и химически нереагирующими; смена фаз вещества не рассматривалась. Также модель не учитывает наличие твердых фракций. В наборе данных параметры варьировались в следующих диапазонах. По физическим параметрам трубы: диаметр — 60–90 мм, длина — 7–50 м, угол наклона — от  $0^\circ$  (восходящее вертикальное течение) до  $90^\circ$  (горизонтальное), шероховатость стенок —  $10^{-3}$ – $10^{-1}$  мм. По свойствам флюида: плотность нефти — 620–850  $\text{кг}/\text{м}^3$ , плотность газа — 0,8–320  $\text{кг}/\text{м}^3$ , динамическая вязкость нефти — 0,2–8,0  $\text{Н} \cdot \text{с}/\text{м}$ , динамическая вязкость газа — 0,01–0,04  $\text{Н} \cdot \text{с}/\text{м}$ , коэффициент поверхностного натяжения (КПН) «нефть – вода» — 17–25  $\text{Н}/\text{м}$ , КПН «газ – нефть» — 0,2–17  $\text{Н}/\text{м}$ , КПН «газ – вода» — 8,8–77  $\text{Н}/\text{м}$ . По параметрам течения: входное давление — 0–350 бар, температура — 15–100  $^\circ\text{C}$ , скорость подачи воды — 0–7,5  $\text{м}/\text{с}$ , скорость подачи нефти — 0–12,5  $\text{м}/\text{с}$ , скорость подачи газа — 0–200  $\text{м}/\text{с}$ . Набор данных покрывает весь диапазон значений КУЖ и реализует 5 режимов течения. Построенная нейросетевая модель является интерполяционной, поэтому диапазон значений синтетического набора данных жестко определяет пределы применимости модели.

Каждый вектор данных (строка таблицы) соответствует одному исполнению программы. Векторы данных не обладают последовательностью и временными зависимостями. Вектор данных включает уникальный набор входных параметров, переданных программе, а также совокупность значений, полученных в результате выполнения программы. Используется следующий набор входных параметров (см. таблицу 1).

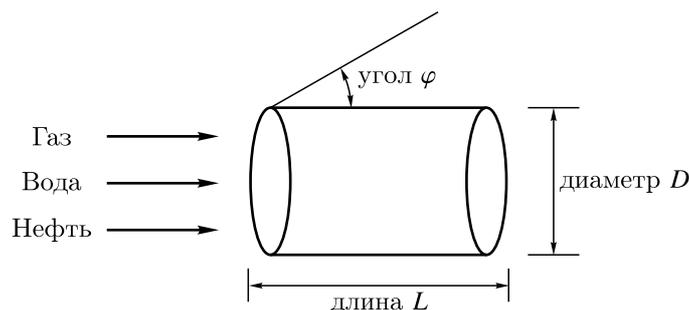


Рис. 1. Графическое изображение трехфазного потока (нефть, газ, вода) в наклонной трубе

Таблица 1. Параметры смеси и трубы

Параметры смеси		Параметры трубы	
Плотность нефти	кг/м <sup>3</sup>	Длина трубы	метр
Плотность газа	кг/м <sup>3</sup>	Угол наклона трубы	градус
Динамическая вязкость газа	Н · с/м <sup>2</sup>	Температура	Кельвин
Динамическая вязкость нефти	Н · с/м <sup>2</sup>	Внутренний диаметр трубы	метр
КПН «нефть – вода»	Н/м	Шероховатость трубы	миллиметр
КПН «газ – нефть»	Н/м	Давление на входе	бар
КПН «газ – вода»	Н/м		
Скорость подачи газа	м/с		
Скорость подачи нефти	м/с		
Скорость подачи воды	м/с		

На рис. 2, а показана матрица корреляций Пирсона для используемого набора данных. Наблюдаются сильные корреляции и антикорреляции между физическими параметрами фаз (КПН, плотность, вязкость). Это связано с тем, что физические параметры указаны на входе в трубу и изменяются пропорционально давлению. Обучающий параметр «перепад давления» не имеет явных корреляций с другими полями набора данных.

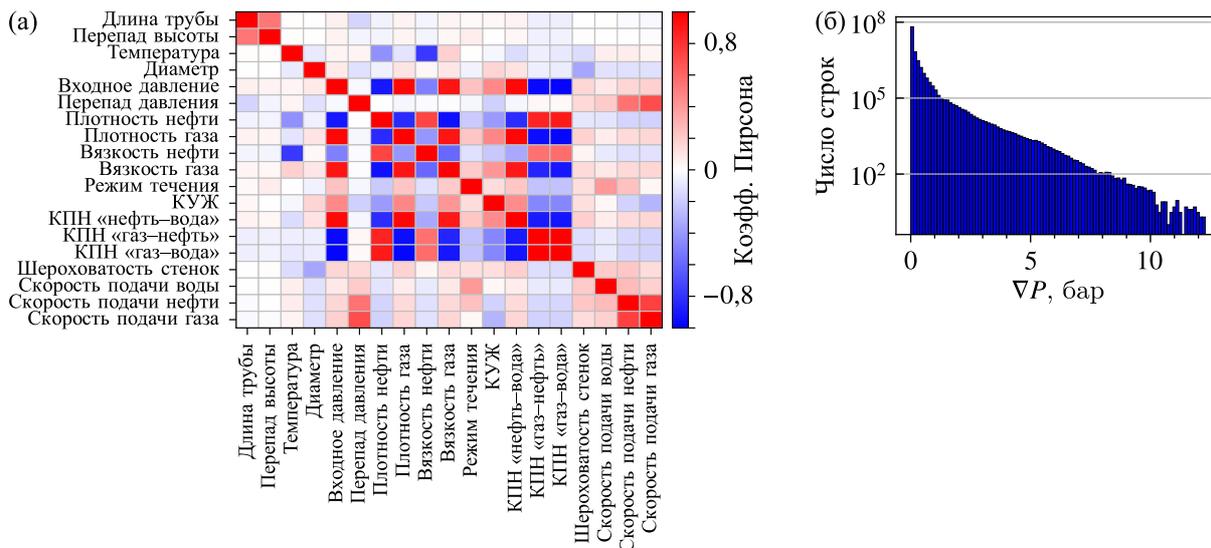


Рис. 2. (а) Матрица корреляций Пирсона между входными параметрами задачи. Цветовая шкала от  $-1$  до  $1$  показывает силу линейной связи соответствующей пары параметров. (б) Распределение значений градиента давления  $\nabla P$  (бар) в исходном (обучающем + тестовом) наборе данных

Проанализированная база данных содержит  $8 \cdot 10^7$  записей. Для целей обучения компьютерных моделей данные были разделены на две части с равновероятным распределением. 80 % записей были использованы для обучающей выборки, оставшиеся 20 % не задействуются при обучении и используются для оценки качества обучения и предсказательной способности моделей.

При создании набора данных приоритет отдавался равномерному покрытию диапазона физических параметров фаз и трубы, что не гарантирует равномерного распределения градиента давления. Распределение градиента давления в наборе данных приведено на рис. 2, б. Число записей с околонулевым перепадом давления на 6 порядков меньше, чем записей с перепадом более 10 бар. Это может негативно сказаться на качестве обучения для случаев с большим перепадом давления.

### 3. Решение задачи регрессионной моделью

Для решения поставленной задачи возможно использовать полносвязную нейронную сеть. Данная архитектура позволяет интегрировать все предоставленные данные в процесс обучения и валидации. Структура сети включает 5 скрытых слоев, каждый из которых содержит 100 нейронов. На выходном слое модели — один нейрон, значение которого равно градиенту давления. В качестве оптимизатора применяется алгоритм Adam, а функция потерь — среднеквадратичная ошибка (MSE).

Для нормализации значений весов модели между первыми 4 слоями добавлена функция активации. В рамках исследования для определения оптимальной архитектуры модели был проведен сравнительный анализ функций активации ReLU, SeLU и Tanh [Dubey et al., 2022]. Результаты работы обученных моделей приведены на рис. 3. Функция SeLU продемонстрировала наилучшие показатели эффективности прогнозирования перепада давления. Сеть с функцией активации Tanh предсказывает, как правило, одно и то же значение. Функция ReLU показала относительно хорошие результаты, но при достижении порогового результата в 5–6 бар не предсказывала значения выше. Наивысшая точность, достигнутая с использованием SeLU, вероятно, обусловлена ее свойством самонормализации, а также наличием ненулевого отрицательного участка, который обеспечивает передачу отрицательных значений с экспоненциальным затуханием. Это позволяет модели более точно выявлять и отражать сложные нелинейные зависимости в данных, что и обусловило выбор данной функции активации для итоговой конфигурации нейронной сети. Дальнейшее сравнение проводилось с функцией активации SeLU.

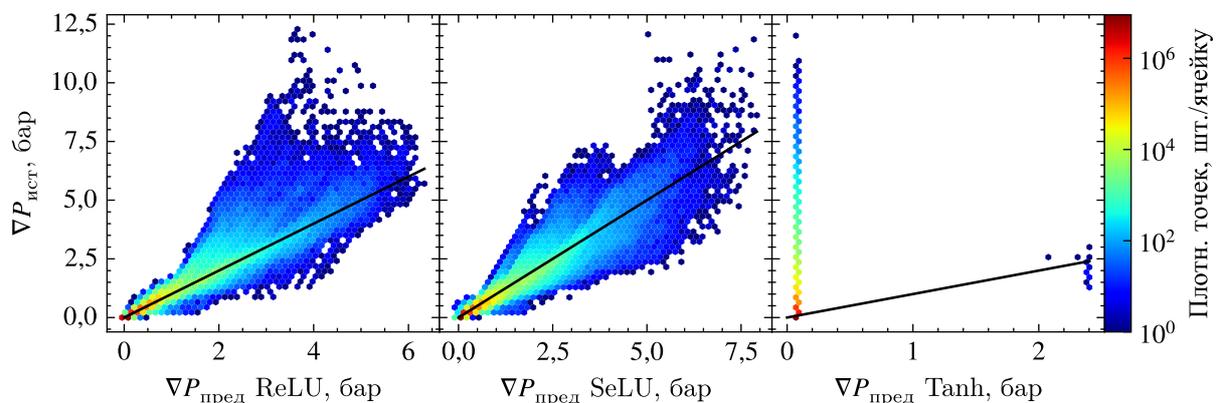


Рис. 3. Сравнение качества предсказания градиента давления  $\nabla P$  (бар) полносвязной моделью с разными функциями активации ReLU, SeLU, Tanh на промежуточных слоях. Цветом показана плотность точек, приходящихся на одну ячейку шестиугольной формы. Черной линией отмечен эталон, когда  $\nabla P_{\text{пред}} = \nabla P_{\text{ист}}$

Для оценки ошибки использовались следующие метрики:

$$R^2 = \frac{\sum_i (y_i - f_i)^2}{\sum_i (y_i - \bar{y})^2},$$

$$\text{MAE} = \frac{\sum_i |y_i - f_i|}{N},$$

$$\text{RMSE} = \sqrt{\frac{\sum_i (y_i - f_i)^2}{N}},$$

где  $y$  — верное значение,  $f$  — результат работы сети. Ошибки по метрикам наилучшей модели составили:  $R^2 = 0,9393$ ;  $\text{MAE} = 0,0233$ ;  $\text{RMSE} = 0,0663$ .

## 4. Подход с разделением нейросети на три части. Описание подхода

Решение задачи прогнозирования перепада давления с помощью единой полносвязной модели нейронной сети дало удовлетворительные результаты, но присутствуют ограничения в точности и интерпретируемости результатов. В связи с этим предложен каскадный подход, основанный на разделении единой нейронной сети на 3 более простые модели, тем самым поделив одну сложную задачу на 3 подзадачи: предсказание КУЖ, идентификация режима течения и непосредственный расчет перепада давления. Данное разбиение позволяет повысить точность и интерпретируемость предсказаний, а также снизить вычислительные затраты. Каждый выход предшествующей нейронной сети используется в качестве дополнительного входного признака для последующей, что способствует обогащению модели на каждом этапе и позволяет учитывать физические взаимосвязи между параметрами потока.

### 4.1. Регрессионная модель для прогнозирования КУЖ

Данная нейросеть предсказывает фактическое значение параметра КУЖ ( $h$ ) — коэффициент отношения объема жидкости к общему объему многофазной смеси в трубопроводе, с учетом проскальзывания фаз относительно друг друга. Помимо названных компонентов, на коэффициент могут оказывать влияние температура, давление или плотность. Для оценки  $h$  используется нейронная сеть, которая состоит из входного слоя с описанными выше параметрами, 5 скрытых слоев по 100 нейронов и с функцией активации SeLU и выходным параметром  $h$ .

Качество обученной модели было проанализировано путем сравнения предсказанных значений с фактическими данными (рис. 4, а). Как показано на диаграмме рассеяния (рис. 4, б), предсказания демонстрируют высокую точность, концентрируясь вблизи линии идеального соответствия (диагонали). Это свидетельствует об отсутствии систематической ошибки и адекватной обобщающей способности построенной регрессионной модели.

Разработанная модель обладает самостоятельной научной и практической ценностью. Ее применение не ограничивается использованием в рамках каскадной структуры; модель может быть применена в качестве автономного инструмента для анализа характеристик многофазных потоков. На основе прогнозируемых значений КУЖ представляется возможным построение диаграмм режимов течения, которые визуализируют переходы между различными режимами в зависимости от изменяющихся эксплуатационных параметров. Подобные диаграммы являются стандартным инструментом в исследованиях многофазных течений и по своей сути аналогичны классическим диаграммам, представленным в фундаментальных работах [Mandhane et al., 1974].

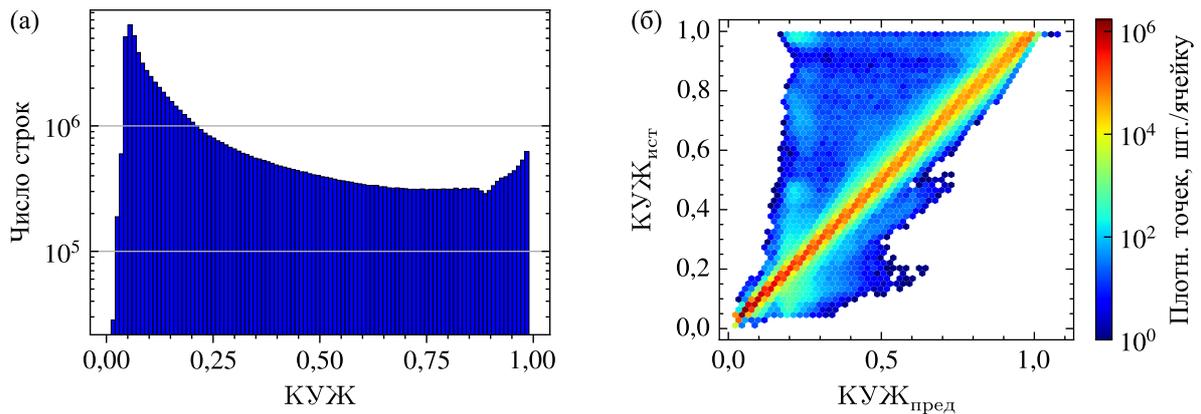


Рис. 4. (а) Распределение значений КУЖ в исходном (обучающем + тестовом) наборе данных. (б) Качество предсказания КУЖ. Цветом показана плотность точек, приходящихся на одну ячейку шестиугольной формы

#### 4.2. Регрессионная модель для прогнозирования режима течения

Следующим этапом была разработана нейронная сеть, цель которой — определить режим течения в канале. Классификация режимов течения приведена в работе [Mandhane et al., 1974]. Режим течения критически влияет на значение перепада давления. Образование газовых пробок может приводить к скачкам давления и остановке течения. Режим зависит как от физических характеристик фаз, так и от скоростей их подачи, а также от угла наклона трубы (рис. 5).

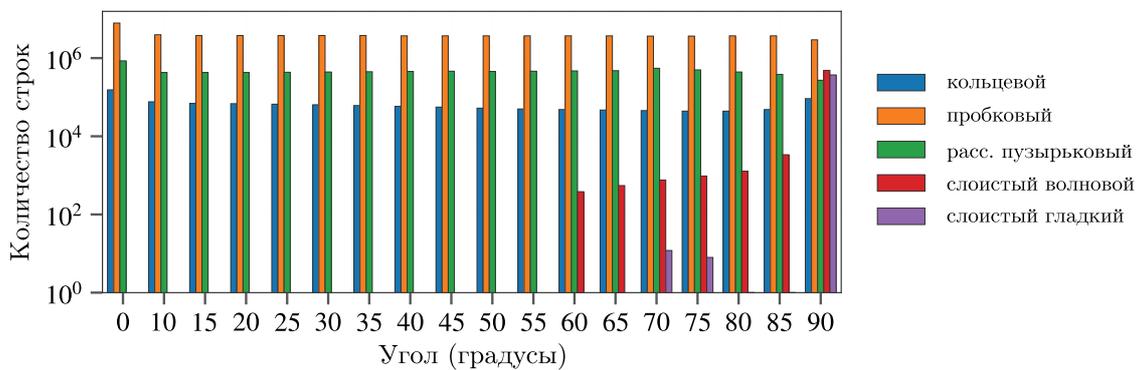


Рис. 5. Распределение числа строк в исходном наборе данных в зависимости от угла наклона трубы в диапазоне от  $0^\circ$  (вертикальное положение с восходящим потоком) до  $90^\circ$  (горизонтальное положение), с разделением на режимы течения

На входном слое используются не только все исходные данные, но и выход предыдущей модели (КУЖ) в качестве одного из входных параметров. Сеть состоит из трех скрытых полносвязных слоев по 100 нейронов. На выходном слое применена функция активации Softmax, что позволяет интерпретировать результаты как вероятности принадлежности к тому или иному классу, а именно, к одному из прогнозируемых режимов многофазного течения. На данном этапе также было проведено сравнительное исследование влияния функций активации на точность модели. Тестирование проводилось для функций ReLU, SeLU и GeLU. Анализ результатов выявил, что функция GeLU демонстрирует наихудшую производительность, допуская значительные ошибки (до 40 %) при разделении кольцевого и пробкового режимов течения. Модель с функцией SeLU показала промежуточный результат с максимальными ошибками около 15 %. Наивысшая точность прогнозирования достигнута с использованием функции ReLU, которая

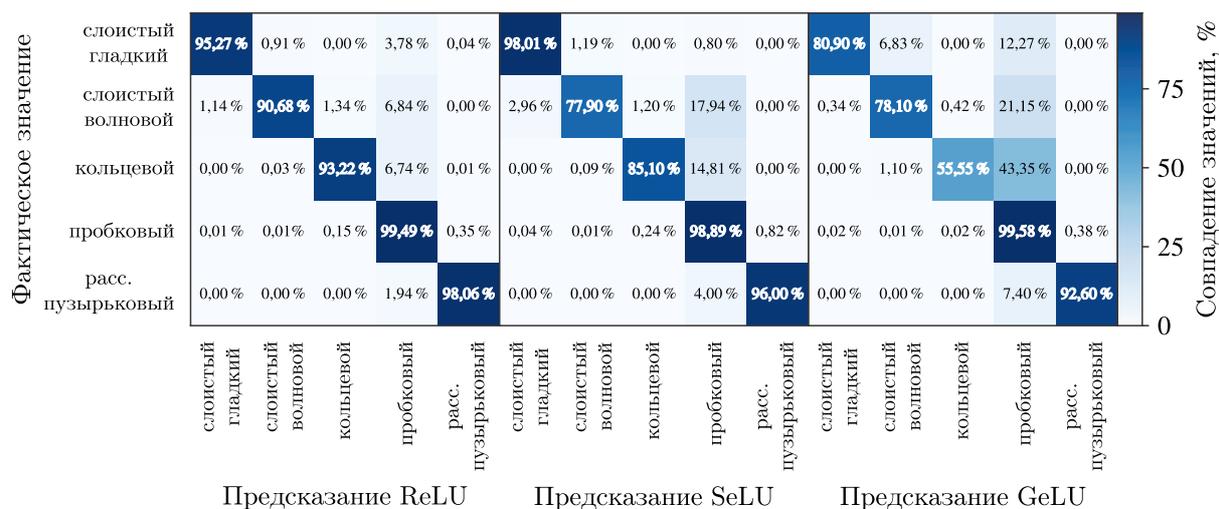


Рис. 6. Матрицы ошибок классификации режимов течения с разными функциями активации. Ось абсцисс — предсказанный режим, ось ординат — истинный режим. Цветом обозначен процент совпадения значений

обеспечила классификацию с точностью не менее 90 % для всех режимов. Качественное сравнение предсказаний, подтверждающее данные выводы, представлено на рис. 6.

На следующем этапе модели использовались предсказания нейронной сети с функцией активации ReLU для достижения наиболее точных результатов.

#### 4.3. Регрессионная модель для прогнозирования перепада давления

Завершающим этапом каскадной модели является прогнозирование перепада давления в трубопроводе. Для решения этой задачи нейронная сеть принимает на вход полный набор исходных параметров течения, дополненный прогнозными переменными, полученными на предыдущих этапах, — расчетным значением КУЖ и вероятностными характеристиками режимов течения.

Архитектура модели включает пять последовательных полносвязных скрытых слоев, содержащих по 100 нейронов каждый. В качестве функции активации была выбрана масштабированная экспоненциальная линейная единица (SeLU), это обусловлено ее ранее подтвержденной эффективностью при решении задачи в рамках данной работы. Выходной слой модели состоит из одного линейного нейрона, возвращающего непосредственную оценку перепада давления.

Ошибки предсказания перепада давления для каскадной архитектуры нейронной сети составили:  $R^2$  — 0,9656; MAE — 0,0152; RMSE — 0,0489. Это означает, что каскадная модель повысила точность своих предсказаний относительно полносвязной регрессивной модели. Визуальная оценка полученных предсказаний подтверждает повышение точности (рис. 7).

Полученные результаты свидетельствуют о том, что предложенная каскадная архитектура превосходит по точности единую полносвязную модель, последовательно и эффективно выявляя сложные зависимости в данных. Интеграция прогнозов от моделей КУЖ и режимов течения в качестве входных признаков позволяет финальной модели более точно обобщать физические закономерности многофазного потока.

## 5. Анализ чувствительности моделей и проверка экспериментальных данных

Для проверки качества работы обученной нейросети использовались данные совместных экспериментов [Sintef, 2024]. Применялись 2 конфигурации. В первой — труба длиной 94 м,

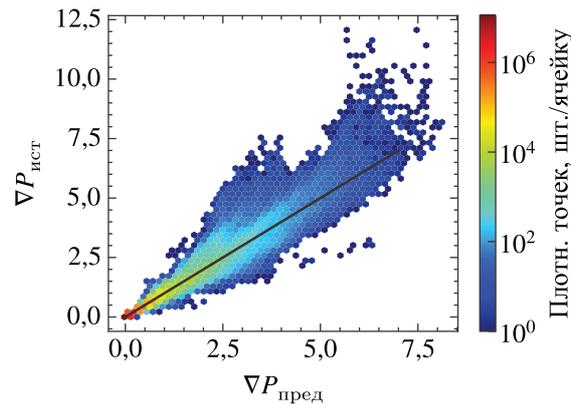


Рис. 7. Качество предсказания градиента давления  $\nabla P$  (бар) каскадной моделью. Цветом показана плотность точек, приходящихся на одну ячейку шестиугольной формы. Черной линией отмечен эталон, когда  $\nabla P_{\text{пред}} = \nabla P_{\text{ист}}$

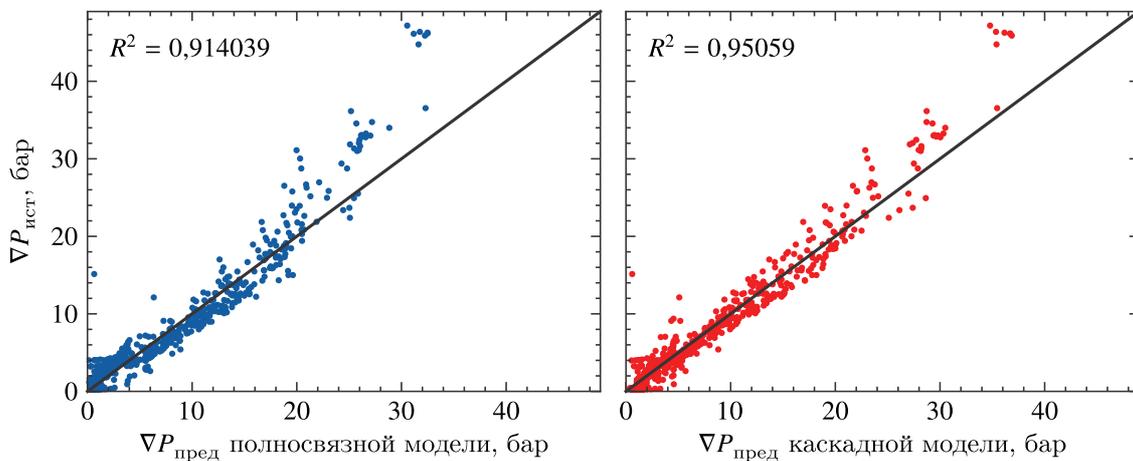


Рис. 8. Сравнение качества предсказаний градиента давления  $\nabla P$  (бар) полносвязной (слева) и каскадной (справа) моделей. На осях абсцисс отмечено предсказанное значение, по осям ординат — истинное значение. Черной линией отмечен эталон, когда  $\nabla P_{\text{пред}} = \nabla P_{\text{ист}}$

диаметром 20 см и наклоном  $2,5^\circ$ . Объемные скорости подачи в интервале  $0\text{--}4,5 \text{ м}^3/\text{с}$  для нефти,  $0\text{--}14 \text{ м}^3/\text{с}$  для газа и  $0\text{--}2,9 \text{ м}^3/\text{с}$  для воды при температуре  $20^\circ\text{C}$ . Вторая конфигурация использует трубу длиной 380 м, диаметром 20 см и наклоном  $2,5^\circ$ . Скорости подачи в интервале  $0\text{--}4,15 \text{ м}^3/\text{с}$  для нефти,  $0\text{--}14,8 \text{ м}^3/\text{с}$  для газа и  $0\text{--}2,83 \text{ м}^3/\text{с}$  для воды при температуре  $20^\circ\text{C}$ . Итоговый набор данных состоит из 862 значений.

На рис. 8 показано сравнение результата работы полносвязной и каскадной моделей. Полносвязная модель сильнее каскадной занижает предсказанный результат для больших значений  $\nabla P$ . Ошибки для полносвязной модели составили:  $R^2$  — 0,9140; MAE — 1,5229; RMSE — 2,4001. Для каскадной:  $R^2$  — 0,9506; MAE — 1,1356; RMSE — 1,8368.

Для выявления не влияющих на решение входных параметров применяются два метода глобального анализа чувствительности. В отличие от локальных методов чувствительности, которые используются в основе алгоритма обучения нейронной сети, глобальные методы позволяют исследовать вклад входных переменных в дисперсию выходного отклика модели по всему пространству параметров.

Метод Соболя [Sobol', 2001] заключается в декомпозиции дисперсии выходной переменной на компоненты, связанные с отдельными параметрами и их комбинациями. Общую диспер-

сию можно выразить как сумму дисперсий, обусловленных отдельными входными параметрами, их парными взаимодействиями и т. д.:

$$D = \sum_{i=1}^d D_i + \sum_{1 \leq i < j \leq d} D_{i,j} + \dots + \sum_{1 \leq i < j < \dots < d} D_{i,j,\dots,d}. \quad (2)$$

Индексы Соболя определяются как отношение частной дисперсии к общей:  $S_i = \frac{D_i}{D}$ ,  $S_{i,j} = \frac{D_{i,j}}{D}$  и т. д. Наиболее показательным, но вычислительно сложным является индекс общего влияния  $S_{t,i}$  [Saltelli et al., 2010], который определяется как суммарный вклад  $i$ -го входного параметра в общую дисперсию во всех возможных комбинациях с другими параметрами.

Значения  $S_{t,i}$  для полностью связанной и каскадной моделей показаны в левой части рис. 9. Анализ показывает схожий результат для обеих моделей и демонстрирует низкую чувствительность моделей к коэффициентам поверхностного натяжения на границах «газ–нефть» и «нефть–вода», а также к вязкости нефти и газа.

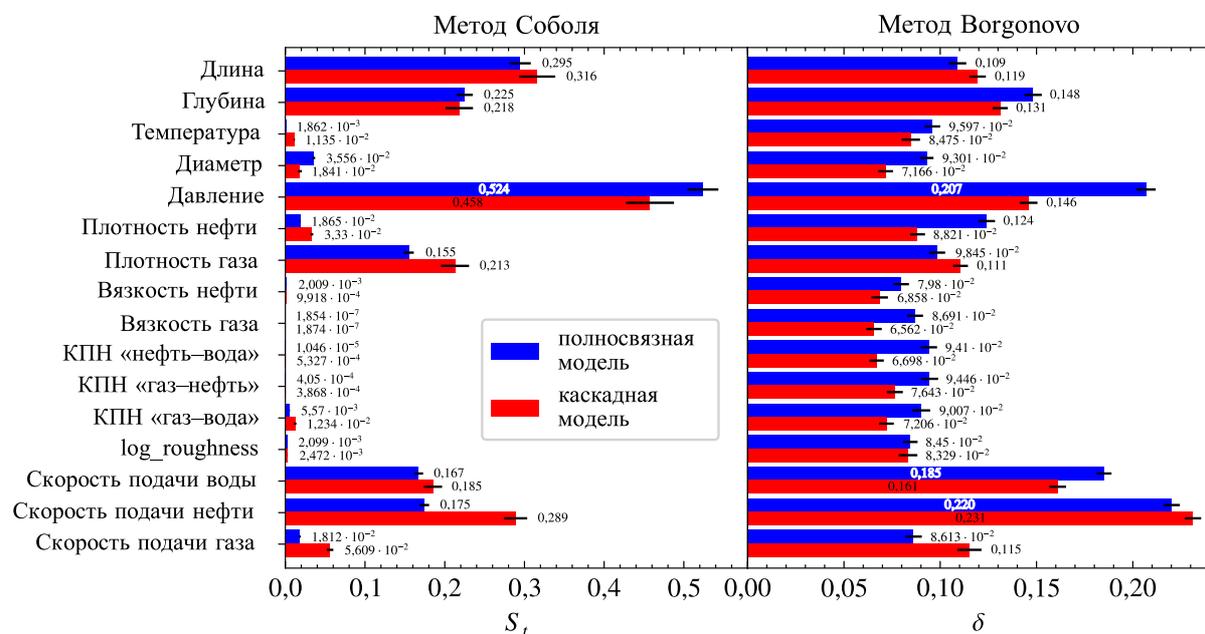


Рис. 9. Результат глобального анализа чувствительности проведенный методом [Sobol', 2001] (слева) и [Borgonovo, 2007] (справа) полностью связанной и каскадной моделей для каждого входного параметра. Черные линии — стандартная ошибка измерений

Метод Соболя применим для моделей, входные параметры которых не имеют корреляций [Sobol', 2001]. В рассматриваемой задаче некоторые параметры коррелируют из-за природной взаимосвязанности физических характеристик флюида (рис. 2, а). Метод глобального анализа чувствительности Borgonovo [Borgonovo, 2007], так же как и  $S_{t,i}$ , дает оценку глобальной чувствительности модели к изменению входных параметров, но может применяться для моделей с коррелирующими входными параметрами. Для  $i$ -го входного параметра вычисляется значение  $\delta_i$ , показывающее, насколько фиксация параметра  $i$  меняет плотность распределения вероятностей выходного параметра. Фактически  $\delta_i$  есть усредненная разность плотности распределения вероятностей. В правой части рис. 9 показан результат анализа. Результат демонстрирует, что все входные параметры достаточным образом влияют на результат. Как и для  $S_{t,i}$ , видно, что наиболее важными параметрами являются скорости подачи нефти и воды, а также давление.

Вычисление индексов Соболя и Borgonovo необходимо проводить используя Монте-Карло (квазислучайное) семплирование точек в  $d$ -мерном пространстве, такое, чтобы точки были распределены максимально равномерно в пространстве и их проекция на любое базисное направление пространства также была равномерна. Общий подход к семплированию описан в [Соболь, Статников, 1981; Sobol', 2001]. Оригинальные последовательности Соболя могут иметь скрытые корреляции в начальных точках, особенно при больших значениях  $d$ .

В этой работе для семплирования используется модификация метода Соболя [Saltelli, 2002], в которой семплирование начинается не с первой точки последовательности, а пропускается некоторое начальное количество точек. После пропуска последовательность стабилизируется и демонстрирует более равномерное распределение значений. Использовалось  $n \cdot (2d + 2)$  семплов, где число входных параметров модели  $d = 16$  и  $n = 2^{16}$  для анализа методом Соболя и  $n = 2^{10}$  методом Borgonovo.

## 6. Заключение

Проведенное исследование формирует основу для последующего развития каскадной модели. Перспективным направлением является ее валидация на реальных данных, а также модернизация архитектуры для учета дополнительных факторов, таких как наличие твердых фаз (песчаные отложения) и нестационарные условия течения.

Несмотря на заложенный потенциал развития, предложенная модель уже обладает значительной научной и практической ценностью. Ее ключевые преимущества заключаются в следующем: низкая вычислительная стоимость, позволяющая развертывание как на стандартных ПК, так и на промышленных вычислительных станциях; высокая степень интерпретируемости результатов; повышенная скорость выполнения прогнозов.

Модульная структура модели обеспечивает не только прозрачность формируемых результатов, но и возможность независимого применения отдельных вычислительных блоков для решения специализированных инженерных задач.

Примером является использование КУЖ. На основе предсказанных значений коэффициента и вероятностей режимов модель позволяет генерировать актуальные диаграммы режимов течения, которые могут служить инструментом для анализа трубопровода. Пример данной диаграммы можно найти в работе [Mandhane et al., 1974].

Благодаря перечисленным преимуществам каскадная модель может быть интегрирована в системы оперативного мониторинга и управления технологическими процессами транспортировки многофазных сред, обеспечивая быстрое прогнозирование ключевых параметров для поддержки принятия решений.

## Выводы

В представленной работе была успешно разработана и протестирована каскадная модель нейронной сети с физической поддержкой, предназначенная для прогнозирования изменения давления трехфазной смеси в трубопроводе. Для этого был создан обширный обучающий и верификационный набор синтетических данных, содержащий  $\approx 8 \cdot 10^7$  записей, сгенерированных с помощью симулятора.

Исследована и реализована прямая регрессионная модель на основе полносвязной нейронной сети. Проведен сравнительный анализ функций активации (ReLU, SeLU, Tanh), в результате которого наилучшие результаты показала функция SeLU. Данная модель достигла удовлетворительной точности с коэффициентом детерминации  $R^2 = 0,9393$ .

Была предложена и успешно реализована каскадная архитектура нейронной сети, смысл которой заключается в декомпозиции сложной задачи прогнозирования перепада давления на

три последовательные и физически интерпретируемые подзадачи: прогнозирование КУЖ, классификация режима течения и непосредственный расчет перепада давления. Данная архитектура позволила не только повысить точность итогового прогноза, но и обогатить модель физически значимыми промежуточными переменными. Важным научным результатом является то, что промежуточные результаты работы, такие как предсказанный КУЖ и режим течения, обладают самостоятельной ценностью и могут быть использованы для построения диаграмм режимов течения — стандартного инструмента анализа в исследованиях многофазных потоков.

Таким образом, проделанная работа подтвердила эффективность применения каскадного подхода к проектированию нейронной сети. Разработанная модель сочетает в себе высокую точность, низкую вычислительную стоимость и прозрачность результатов, обеспечиваемую ее модульной структурой. Эти преимущества открывают широкие возможности для практического применения модели в системах оперативного мониторинга и управления технологическими процессами, а также для ее интеграции в качестве ядра цифровых двойников гидравлических систем с многофазными потоками.

## Список литературы (References)

- Соболь И. М., Статников Р. Б.* Выбор оптимальных параметров в задачах со многими критериями. — М.: Наука, 1981.
- Sobol' I. M., Statnikov R. B.* *Vybor optimal'nykh parametrov v zadachakh so mnogimi kriteriyami* [Selecting optimal parameters in multicriteria problems]. — Moscow: Nauka, 1981 (in Russian).
- Al-Rbeawi S.* Pseudo-steady state inflow performance relationship of reservoirs undergoing multiphase flow and different wellbore conditions // *Journal of Natural Gas Science and Engineering*. — 2019. — Vol. 68. — P. 102912.
- Asheim H.* MONA An accurate two-phase well flow model based on phase slippage // *SPE Production Engineering*. — 1986. — Vol. 1, No. 03. — P. 221–230.
- Bahrami S., Alamdari S., Farajmashaei M., Behbahani M., Jamshidi S., Bahrami B.* Application of artificial neural network to multiphase flow metering: A review // *Flow Measurement and Instrumentation*. — 2024. — Vol. 97. — P. 102601.
- Beggs D. H., Brill J. P.* A study of two-phase flow in inclined pipes // *Journal of Petroleum technology*. — 1973. — Vol. 25, No. 05. — P. 607–617.
- Bikmukhametov T., Jäschke J.* Oil production monitoring using gradient boosting machine learning algorithm // *IFAC-PapersOnLine*. — 2019. — Vol. 52, No. 1. — P. 514–519.
- Borgonovo E.* A new uncertainty importance measure // *Reliability Engineering & System Safety*. — 2007. — Vol. 92, No. 6. — P. 771–784.
- Cui G., Tan Y., Chen T., Feng X.-T., Elsworth D., Pan Z., Wang C.* Multidomain two-phase flow model to study the impacts of hydraulic fracturing on shale gas production // *Energy and Fuels*. — 2020. — Vol. 34, No. 4. — P. 4273–4288.
- Dubey S. R., Singh S. K., Chaudhuri B. B.* Activation functions in deep learning: A comprehensive survey and benchmark // *Neurocomputing*. — 2022. — Vol. 503. — P. 92–108.
- Epelle E. I., Gerogiorgis D. I.* Drill cuttings transport and deposition in complex annular geometries of deviated oil and gas wells: A multiphase flow analysis of positional variability // *Chemical Engineering Research and Design*. — 2019. — Vol. 151. — P. 214–230.
- Feng M., Liu L., Jia H., Xu G., Yang X.* FlowDA: unsupervised domain adaptive framework for optical flow estimation // *arXiv preprint*. — 2023. — arXiv:2312.16995
- Frau L., Susto G. A., Barbariol T., Feltresi E.* Uncertainty estimation for machine learning models in multiphase flow applications // *Informatics*. — 2021. — Vol. 8, No. 3. — P. 58.
- Hernandez J. S., Valencia C., Ratkovich N., Torres C. F., Muñoz F.* Data driven methodology for model selection in flow pattern prediction // *Heliyon*. — 2019. — Vol. 5, No. 11.

- Hou Z., Yan T., Li Z., Feng J., Sun S., Yuan Y. Temperature prediction of two phase flow in wellbore using modified heat transfer model: An experimental analysis // *Applied Thermal Engineering*. — 2019. — Vol. 149. — P. 54–61.
- Jiang Z., Wang H., Yang Y., Li Y. Comparison of machine learning methods for multiphase flowrate prediction // *2019 IEEE International Conference on Imaging Systems and Techniques (IST)*. — IEEE, 2019. — P. 1–6.
- Kanin E., Vainshtein A., Osiptsov A., Burnaev E. The method of calculation the pressure gradient in multiphase flow in the pipe segment based on the machine learning algorithms // *IOP Conference Series: Earth and Environmental Science*. — 2018. — Vol. 193. — P. 012028.
- Kanin E. A., Osiptsov A. A., Vainshtein A. L., Burnaev E. V. A predictive model for steady-state multiphase pipe flow: Machine learning on lab data // *Journal of Petroleum Science and Engineering*. — 2019. — Vol. 180. — P. 727–746.
- Li X., Miskimins J. L., Sutton R. P., Hoffman B. T. Multiphase flow pattern recognition in horizontal and upward gas-liquid flow using support vector machine models // *SPE Annual Technical Conference and Exhibition*. — SPE, 2014.
- Mandhane J. M., Gregory G. A., Aziz K. A flow pattern map for gas-liquid flow in horizontal pipes // *International Journal of Multiphase Flow*. — 1974. — Vol. 1, No. 4. — P. 537–553.
- Opoku D., Al-Ghamdi A., Osei A. Novel method to estimate bottom hole pressure in multiphase flow using Quasi-Monte Carlo method // *International Petroleum Technology Conference*. — IPTC, 2020.
- Pei Y., Zhang N., Zhou H., Zhang S., Zhang W., Zhang J. Simulation of multiphase flow pattern, effective distance and filling ratio in hydraulic fracture // *Journal of Petroleum Exploration and Production Technology*. — 2019. — Vol. 10, No. 3. — P. 933–942.
- Pereyra E., Torres C., Mohan R., Gomez L., Kouba G., Shoham O. A methodology and database to quantify the confidence level of methods for gas-liquid two-phase flow pattern prediction // *Chemical Engineering Research and Design*. — 2012. — Vol. 90, No. 4. — P. 507–513.
- Saltelli A. Making best use of model evaluations to compute sensitivity indices // *Computer Physics Communications*. — 2002. — Vol. 145, No. 2. — P. 280–297.
- Saltelli A., Annoni P., Azzini I., Campolongo F., Ratto M., Tarantola S. Variance based sensitivity analysis of model output. Design and estimator for the total sensitivity index // *Computer Physics Communications*. — 2010. — Vol. 181, No. 2. — P. 259–270.
- SINTEF, IFE. FlowDa multiphase flow simulator. — [Electronic resource]. — <https://www.sintef.no/projectweb/flowda/> (accessed: 11.12.2024).
- Sobol' I. M. Global sensitivity indices for nonlinear mathematical models and their Monte Carlo estimates // *Mathematics and Computers in Simulation*. — 2001. — Vol. 55, No. 1–3. — P. 271–280.
- Sun Y., Guo H., Liang H., Li A., Zhang Y., Zhang D. A comparative study of oil-water two-phase flow pattern prediction based on the GA-BP neural network and random forest algorithm // *Processes*. — 2023. — Vol. 11, No. 11. — P. 3155.
- Tariq Z., Mahmoud M., Abdulraheem A. Real-time prognosis of flowing bottom-hole pressure in a vertical well for a multiphase flow using computational intelligence techniques // *Journal of Petroleum Exploration and Production Technology*. — 2019. — Vol. 10, No. 4. — P. 1411–1428.
- Trafalis T. B., Oladunni O., Papavassiliou D. V. Two-phase flow regime identification with a multiclassification support vector machine (SVM) model // *Industrial and Engineering Chemistry Research*. — 2005. — Vol. 44, No. 12. — P. 4414–4426.
- Zhang F., Miska S., Yu M., Ozbayoglu E., Takach N. An Eulerian approach for characterization of solid suspension in multiphase flow systems and its application in hole cleaning during drilling // *ASME 2016 International Mechanical Engineering Congress and Exposition*. — ASM, 2016.