

Классификация режимов многофазных течений методами нейросетевого анализа

Янис Валдисович Пурицкис^{1, 2✉}, Владимир Евгеньевич Вершинин^{1, 2}

¹ Тюменский нефтяной научный центр, Тюмень, Россия

² Тюменский государственный университет, Тюмень, Россия

Контакт для переписки: yvpuritskis@tnnc.rosneft.ru ✉

Аннотация. В целом ряде отраслей промышленности — нефтегазовой, химической и атомной — возникает задача контроля режимов многофазных течений. В атомной и химической промышленности режим течения напрямую влияет на характер технологических процессов и их безопасность. В нефтегазовой промышленности добываемая из скважин продукция изначально представляет собой смесь нефти, воды и газа, и задача контроля режима течения связана с соблюдением допустимых параметров работы насосного и контрольно-регулирующего оборудования. При использовании многофазных расходомеров проточного типа алгоритмы расчета расходов фаз в многофазном потоке весьма чувствительны к нарушению однородности и гомогенности измеряемого потока. Избыточное зашумление сигнала датчиков давления, объемного содержания и расхода, вызванное снаряженным, пробковым или расслоенным режимом, способно отрицательно сказаться на точности измерений. Как правило, при определении текущего режима используются карты режимов течения. Этот подход основан на расчете ряда безразмерных параметров потока (числа Фруда, параметра Локкарта — Мартинелли и т. д.). В случае динамически изменяющегося потока этот подход может оказаться непригодным. Для более точного и надежного определения режимов течения предлагается использовать прямой метод анализа пространственного распределения фаз в потоке и распознавание типа потока с помощью искусственных нейронных сетей сверточного типа. Такой подход позволяет избавиться от ошибок классификации и получить более точную информацию о потоке.

Целью исследования является разработка методики нейросетевого анализа изображений многофазного потока с последующим определением его типа. В ходе выполнения работы рассмотрены подходы к формированию обучающей выборки,

осуществлен поиск оптимальной структуры нейронной сети и дана оценка точности при классификации многофазных режимов течения нейронной сетью сверточного типа. Исследование проведено на двух типах данных: 1) синтетических изображениях, полученных с помощью численного моделирования многофазных течений, и 2) экспериментально полученных изображениях потока на стенде многофазных потоков.

Ключевые слова: нейронная сеть, расходомерия, многофазные потоки, карты режимов течения, режимы течения

Цитирование: Пурицкис Я. В., Вершинин В. Е. 2023. Классификация режимов многофазных течений методами нейросетевого анализа // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. Том 9. № 4 (36). С. 76–90. <https://doi.org/10.21684/2411-7978-2023-9-4-76-90>

Поступила 17.10.2023; одобрена 23.10.2023; принята 15.12.2023

Development of the concept of a multiphase flowmeter

Janis V. Puritskis^{1,2}✉, Vladimir E. Vershinin^{1,2}

¹ Tyumen Petroleum Research Center, Tyumen, Russia

² University of Tyumen, Tyumen, Russia

Corresponding author: yvpuritskis@tnnc.rosneft.ru✉

Abstract. In a number of industries: oil and gas, chemical and nuclear industries, the task of controlling multiphase flow regimes arises. In the nuclear and chemical industries, the flow regime directly affects the nature of technological processes and their safety. In the oil and gas industry, the products extracted from wells are usually a mixture of oil, water and gas, and the task of monitoring the flow regime is related to compliance with the permissible parameters of pumping and control equipment. When using multiphase flowmeters of the flow type, the algorithms for calculating phase flow rates in a multiphase flow are very sensitive to a violation of the uniformity and homogeneity of the measured flow. Excessive noise of the signal of pressure sensors, volume content and flow caused by projectile, cork or stratified modes can negatively affect the accuracy of measurements. As a rule, flow mode maps are used when determining the current mode. This approach is based on the calculation of a number of dimensionless flow parameters (Froude number, Lockhart–Martinelli parameter, etc.). In the case of a dynamically changing flow, this approach may

not be suitable. For a more accurate and reliable determination of flow modes, it is proposed to use a direct method of analyzing the spatial distribution of phases in the flow and recognizing the type of flow using artificial convolutional neural networks. This approach allows you to get rid of classification errors and get more accurate information about the flow.

The aim of the study is to develop a technique for neural network analysis of images of a multiphase flow with subsequent determination of its type. In the course of the work, approaches to the formation of a training sample are considered, the search for the optimal structure of the neural network is carried out and an accuracy assessment is given for the classification of multiphase flow modes by a convolutional neural network. The study was carried out on two types of data: 1) synthetic images obtained using numerical simulation of multiphase flows, and 2) experimentally obtained flow images on a multiphase flow stand.

Keywords: neural network, flowmetry, multiphase flows, flow mode maps, flow modes

Citation: Puritskis, J. V., & Vershinin, V. E. (2023). Development of the concept of a multiphase flowmeter. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*, 9(4), 76–90. <https://doi.org/10.21684/2411-7978-2023-9-4-76-90>

Received October 17, 2023; Reviewed October 23, 2023; Accepted December 15, 2023

Введение

Стремительное распространение искусственных нейронных сетей (ИНС) при решении различных прикладных задач обработки информации не обошло стороной и область распознавания изображений. Наиболее впечатляющие результаты в этой области показывают нейронные сети сверточного типа. Основной при этом выступает задача классификации объектов по их изображению [Хайкин, 2019]. После предварительного обучения на массиве изображений объектов, относящихся к тому или иному классу, нейронная сеть способна с высокой достоверностью по характерным визуальным признакам определять принадлежность верифицируемых объектов к указанным классам. В качестве анализируемых изображений могут выступать фотографии, элементы графиков рабочих процессов и пр. Структура многофазного потока определяется формой границы раздела фаз в потоке. Она существенно зависит от соотношения фаз, скорости, а также их физических свойств. Существует целый ряд областей техники, в которых структура потока может оказывать влияние на ход технологического процесса. Примерами могут служить парожидкостные системы охлаждения технических устройств, химические реакторы различного назначения и т. п. Характерным примером подобного типа являются задачи контроля и учета расхода фаз в продукции добывающих скважин. Существующая тенденция цифровизации и автоматизации технологических процессов сопровождается массовым оснащением скважин (кустов скважин) многофазными расходомерами. В основе работы многофазных расходомеров лежат алгоритмы обработки

сигналов, поступающих от системы датчиков. Калибровка подобных информационных систем производится в заводских условиях на специальных проливных стендах, формирующих, как правило, однородный поток. Учет характера режима течения, отличающегося от заводских условий, позволяет повысить точность измерения за счет введения необходимых корректировок в методику расчета расхода фаз.

Для определения режима традиционно используют карты режимов потока. Они представляют собой диаграммы с выделенными на них областями, соответствующими тому или иному типу течения. Чтобы определить режим течения, на основании произведенных замеров скоростей, плотности и соотношений фаз вычисляются требуемые безразмерные параметры потока (число Фруда, параметр Локкарта — Мартинелли и др.), позволяющие определить текущее состояние на диаграмме. В условиях исходной неточности измерения и нестационарности потоков положение рассчитанной точки будет меняться, что может приводить к дальнейшим неопределенностям и порождать ошибки последующих расчетов расхода фаз. Альтернативным методом может являться использование прямого анализа распределения фаз в потоке с применением ИНС.

Режимы течения

Структура многофазного потока зависит от соотношения сил трения, гравитации и поверхностного натяжения, действующих внутри потока. При этом форма межфазной границы динамически изменяется, сохраняя некоторые общие признаки, позволяющие ввести классификацию режима течения. Существует общепринятая классификация режимов потока [Гриценко и др., 1994], согласно которой различают режимы горизонтальных и вертикальных течений.

Примеры типичной структуры различных режимов многофазных течений в горизонтальных трубах представлены на рис. 1 (см. также [Уоллис, 1972; Brill, Mukherjee, 1999]). Доля газа в потоке минимальна при пузырьковом режиме и максимальна при кольцевом.

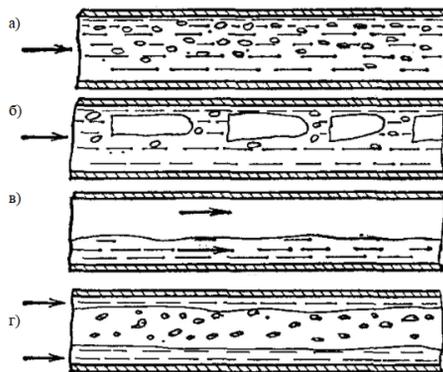


Рис. 1. Структуры газожидкостных потоков в горизонтальных трубах [Brill, Mukherjee, 1999]: а — пузырьковый, б — пробковый, в — расслоенно-волновой, г — кольцевой

Fig. 1. Structures of gas-liquid flows in horizontal pipes [Brill, Mukherjee, 1999]: а — bubble, б — cork, в — wave, г — annular

В зависимости от установившегося режима потока многофазной жидкости используются разные эмпирические корреляции и механистические модели для предсказания характеристик потока [Brill, Mukherjee, 1999]. Практически все методы прогнозирования режима течения построены на основе экспериментальных данных, полученных при исследовании систем низкого давления, в которых массообмен между фазами незначителен, а в смеси присутствует всего одна жидкая фаза. Вследствие этого данные методы могут оказаться недостаточно точными для скважин с высокими давлениями и температурой или в случае добычи нефти вместе с водой.

Карты режимов течения

В данной работе исследовались структуры режимов течения в горизонтальных трубах. Для горизонтальных труб применимы карты режимов течения [Taitel, Dukler, 1976], показанные на рис. 2. На этой карте выделены режимы: кольцевой, пузырьковый, волновой с расслоенным, перемежающийся.

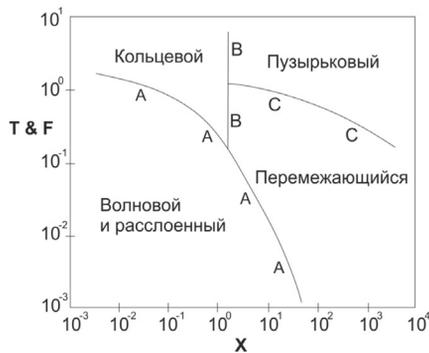


Рис. 2. Карта режимов течения для горизонтальных каналов [Taitel, Dukler, 1976]: кривые А, В, С — переход между режимами течения; F — число Фруда; X — параметр Локхарта — Мартинелли; T — модификация числа Фруда

Fig. 2. Flow regime map for horizontal channels [Taitel, Dukler, 1976]: curves A, B, C — the transition between flow regimes; F — Froude number; X — Lockhart–Martinelli parameter; T — modified Froude number

Границы между режимами определяются числом Фруда и параметром Локхарта — Мартинелли [Brill, Mukherjee, 1999]:

$$F = w_{\Gamma} \sqrt{\frac{\rho_{\Gamma}}{(\rho_{\text{ж}} - \rho_{\Gamma})gD}}, \quad (1)$$

$$X = \sqrt{\left(\frac{dp}{dz}\right)_{\text{ж}} / \left(\frac{dp}{dz}\right)_{\Gamma}}, \quad (2)$$

где F — число Фруда; X — параметр Локхарта — Мартинелли; ρ_{Γ} и $\rho_{\text{ж}}$ — плотности газа и жидкости, кг/м³; g — ускорение свободного падения, м/с²; D — диаметр канала, м;

w_r — приведенная скорость течения газа (рассчитывается по расходу газа), м/с; $(dp/dz)_ж$ и $(dp/dz)_r$ — градиенты давления в рассматриваемом канале при течении в нем только жидкой или только газовой фазы с их действительными расходами.

Границы А и В на рис. 2 определяются переменными X и F , граница С — X и T . Параметр X на границе пузырькового (или перемежающегося) режима с кольцевым принимает постоянное значение 1,6. При $X > 1,6$ режим течения переходит в перемежающийся, при $X < 1,6$ — в кольцевой. Граница пузырькового и перемежающегося режимов определяется параметром X и числом T , которое можно рассматривать как модификацию числа Фруда, определяемого по скорости жидкой фазы:

$$T = \sqrt{\frac{(dp/dz)_ж}{(\rho_ж - \rho_r)g}} \quad (3)$$

Методы

Нейронные сети как инструмент распознавания

Для решения задачи классификации режима течения использовались сверточные нейронные сети, которые способны распознавать и классифицировать различные изображения. Сверточная нейронная сеть — это ИНС специальной архитектуры: односторонняя, без обратных связей, многослойная. В архитектуре сверточной нейронной сети используется операция свертки, когда ограниченная матрица весов «двигается» по всему обрабатываемому изображению. Данные после обработки изображения поступают в первый сверточный слой, в котором изображения обрабатываются с помощью ядра свертки. Затем данные поступают в слой подвыборки, представляющий собой уплотненные карты признаков. В конце каждой сверточной нейронной сети находится полносвязный слой, в котором хранятся все полученные данные [Галушкин, Цыпкин, 2015; Ширяев, 2016; Хайкин, 2019].

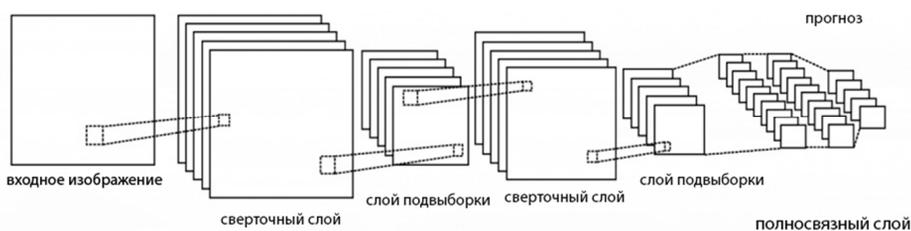


Рис. 3. Последовательность обработки сигнала в сверточной нейронной сети

Fig. 3. The sequence of signal processing in a convolutional neural network

Численное моделирование двухфазного течения

Для получения синтетических изображений двухфазного потока использовалось численное моделирование течения газожидкостной смеси в горизонтальной трубе. Все расчеты производились с помощью нестационарного двухфазного решателя InterFOAM

на платформе для численного моделирования OpenFOAM. Данный решатель моделирует течение двух несмешивающихся фаз с использованием метода VOF (volume of fluid method) [Ганопольский и др., 2020]. InterFOAM представляет собой расчетный модуль решения модифицированных уравнений Навье — Стокса для двух несжимаемых фаз. Численное решение ищется методом конечных объемов с разбиением расчетной области на непересекающиеся ячейки. В основе VOF-метода лежит идея введения переменной α — относительного объема жидкости, содержащейся в ячейке. В случае, когда $\alpha = 1$, жидкость полностью занимает ячейку, при $\alpha = 0$ ячейка заполнена газовой фазой. При $0 < \alpha < 1$ ячейка содержит обе фазы, разделенные свободной поверхностью. Параметр α позволяет определять пространственное положение границы фаз. Для этого используются алгоритмы построения непрерывной поверхности, разделяющей каждую ячейку в заданной объемной пропорции [Boundary Conditions — OpenFOAM-4.1, 2017].

Система уравнений включает в себя уравнения изменения импульса, неразрывности и уравнение переноса для α [Boundary Conditions — OpenFOAM-4.1, 2017; Звонарев, 2019]:

$$\frac{\partial \rho}{\partial t} + \nabla \cdot \rho u = 0, \quad (4)$$

$$\frac{\partial(\rho u)}{\partial t} + (\nabla \cdot \rho u)u = -\nabla p + \nabla \cdot (\mu \nabla u) + \rho g + F_s, \quad (5)$$

$$\frac{\partial(\alpha)}{\partial t} + u \cdot \nabla \alpha + \nabla \cdot (u_c \alpha (1 - \alpha)) = 0, \quad (6)$$

где средневзвешенная скорость потока:

$$u = \alpha u_1 + (1 - \alpha)u_2, \quad (7)$$

скорость сжатия:
$$u_c = C_\alpha |u| \frac{\nabla \alpha}{|\nabla \alpha|}, \quad (8)$$

средняя плотность:
$$\rho = \alpha \rho_1 + (1 - \alpha)\rho_2, \quad (9)$$

средняя вязкость:
$$\mu = \alpha \mu_1 + (1 - \alpha)\mu_2. \quad (10)$$

Здесь μ — вязкость, сП; F_s — сила поверхностного натяжения, Н/м; g — ускорение свободного падения, м/с²; p — давление, Па; t — время, с; u — скорость, м/с; u_c — скорость сжатия, м/с; ρ — плотность, кг/м³. Индексированные переменные относятся к первой и второй фазе соответственно.

Результаты

Результаты численного моделирования

Для проверки работоспособности сверточной нейронной сети были численно смоделированы газожидкостные потоки для четырех основных режимов течения: слоистого, перемежающегося, кольцевого, пузырькового.

Для моделирования потоков была построена модель горизонтальной протяженной трубы. Для расчета использовались следующие параметры: гидравлический диаметр трубы — 0,08 м; размер ячеек расчетной сетки — $0,0018 \times 0,0018$ м; диапазон скоростей потока — от 0,1 до 15 м/с; газосодержание — от 0,1 до 0,9; плотность жидкости — 820 кг/м^3 ; плотность газа — 12 кг/м^3 ; кинематическая вязкость жидкости — $4 \cdot 10^{-5} \text{ м}^2/\text{с}$; кинематическая вязкость газа — $1,48 \cdot 10^{-5} \text{ м}^2/\text{с}$.

Режимы течения определялись по картам режимов течения [Taitel, Dukler, 1976] исходя из задаваемых при моделировании характеристик потока и верифицировались визуально [Чисолм, 1986]. Пример изображений потока, полученных в результате моделирования, представлен на рис. 4.

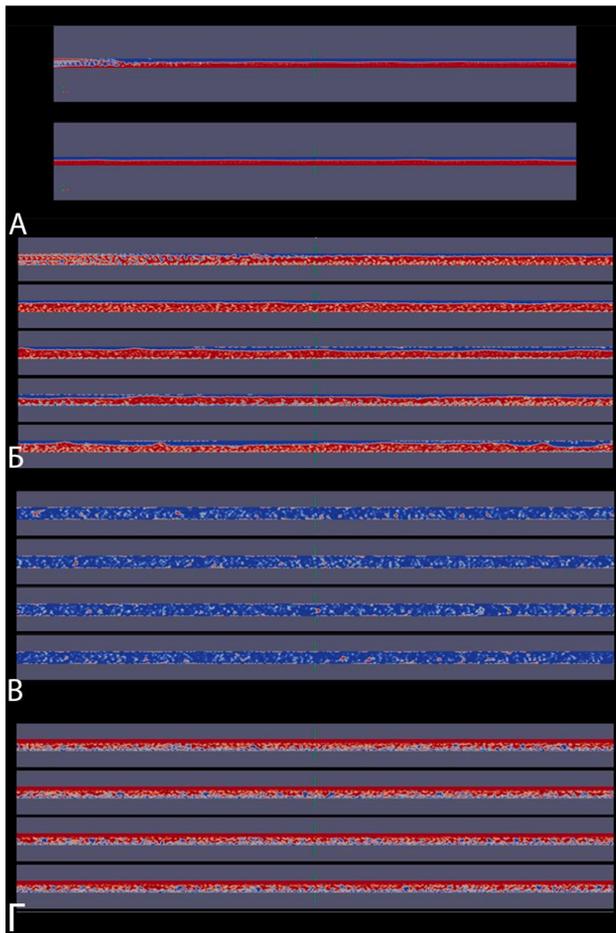


Рис. 4. Результаты численного моделирования различных режимов двухфазного газожидкостного потока: а — расслоенно-волновой, б — перемежающийся, в — кольцевой, г — пузырьковый

Fig. 4. Results of numerical simulation of various modes of two-phase gas-liquid flow: а — wave, б — churn, в — annular, г — bubble

Для формирования обучающей и тестовой выборок для каждого режима течения выделялись одинаковые по размерам изображения участков потока. При этом соблюдался баланс классов. В каждом классе было одинаковое количество изображений. Размер изображений, поступающих для дальнейшей обработки в нейронную сеть, составлял 100×100 пикселей. Всего для обучения было получено 24 000 изображений режимов потоков, для проверки качества обучения — 8 000 изображений и столько же для тестовой выборки. В общей сложности использовалось 40 000 изображений. Примеры изображений, подававшихся на вход нейронной сети, приведены на рис. 5.

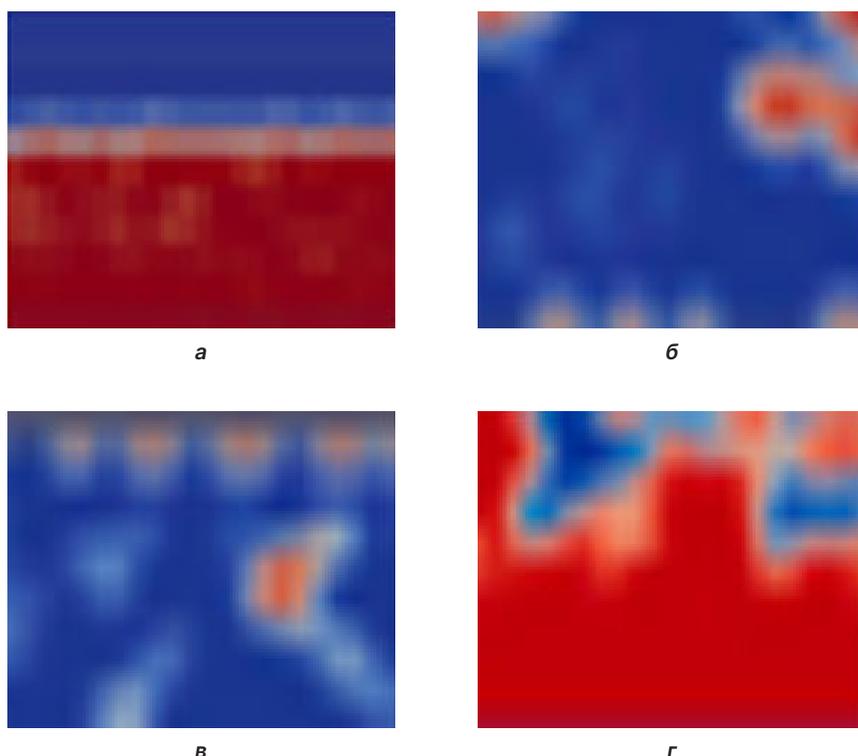


Рис. 5. Примеры изображений различных режимов течения при обучении нейронной сети: а — расслоенно-волновой, б — перемежающийся, в — кольцевой, г — пузырьковый

Fig. 5. Examples of images of various flow modes during neural network training: а — wave, б — churn, в — annular, г — bubble

Для достижения наилучшей точности при обучении варьировалось число эпох обучения. На рис. 6 представлено поведение функции потерь (*loss*). Наилучшую точность классификации (98,6%) показало обучение с количеством эпох порядка 50. На рис. 7 представлен график зависимости доли верных ответов от числа эпох обучения. Дальнейшее увеличение числа эпох приводит к переобучению ИНС и ухудшению точности классификации.

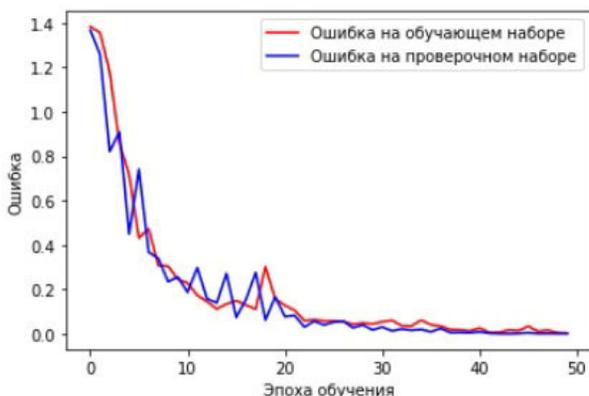


Рис. 6. График зависимости ошибки от количества эпох в процессе обучения для данных численного моделирования

Fig. 6. Graph of the error dependence on the number of epochs in the learning process for numerical simulation data

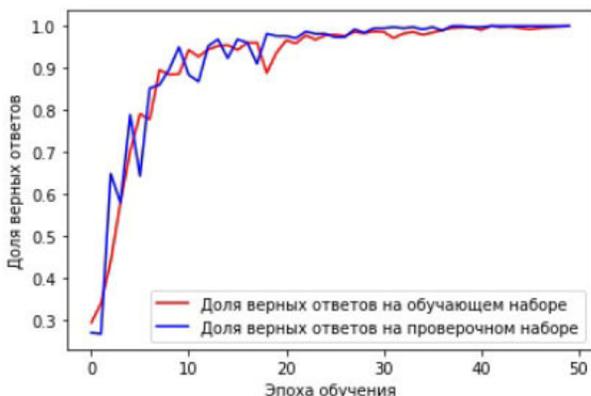


Рис. 7. График зависимости доли верных ответов от количества эпох в процессе обучения для данных численного моделирования

Fig. 7. Graph of the dependence of the proportion of correct answers on the number of epochs in the learning process for numerical simulation data

Экспериментальные данные

Следующим этапом решения задачи нейросетевой классификации режимов течения была обработка изображений, полученных в результате фотофиксации структуры реальных газожидкостных потоков на стенде [Darwich и др., 1991]. Лабораторно-исследовательский стенд газожидкостных потоков Физико-технического института ТюмГУ предназначен для работы с тремя фазами [Мамаев и др., 1978; Бирюков и др., 1987]. На стенде создавались газожидкостные потоки путем смешения воды и воздуха. Возможности стенда позволили создать четыре режима течения: слоистый, перемежающийся, кольцевой, пузырьковый.

Фотофиксация структуры потока производилась после формирования установившегося режима [Цейтлин, 1977; State of the Art Multiphase Flow Metering, 2004; Плотникова, 2012]. Примеры полученных изображений отдельных участков газожидкостного потока представлены на рис. 8.

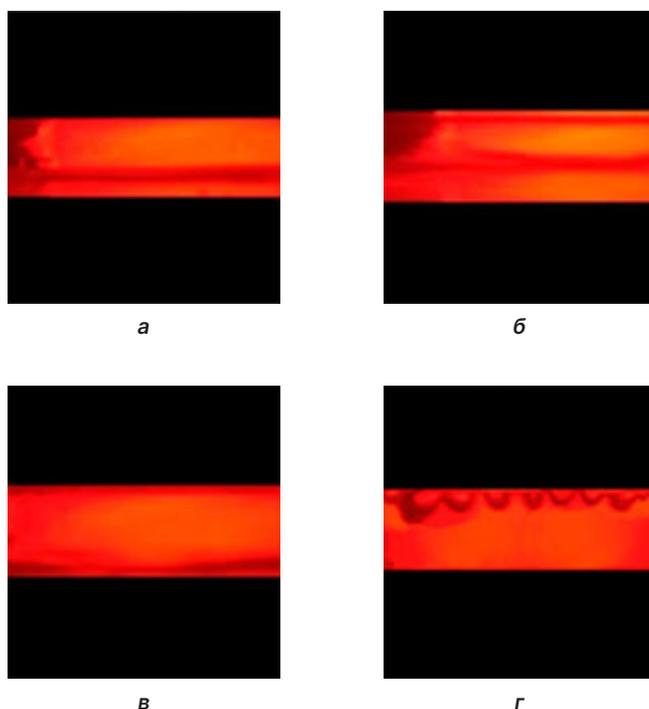


Рис. 8. Фотографии газожидкостного потока: а — расслоенный, б — перемежающийся, в — кольцевой, г — пузырьковый

Fig. 8. Photos of the gas-liquid flow: a — stratified, б — churn, в — annular, г — bubble

Классификация режимов течения производилась визуально. У каждого из выделенных режимов течения есть свои особенности [Рид и др., 1982]. В слоистом режиме течения четкое разделение двух фаз: в нижней части жидкая фаза, в верхней — газовая. В перемежающемся режиме преобладает жидкая фаза, которая движется в виде волн, а газовая фаза находится в верхней части канала. В кольцевом режиме течения преобладает газовая фаза, продвигающаяся по каналу в форме овала. У пузырькового режима течения ярко выраженное скопление пузырьков воздуха в верхней части канала [Pan, Yang, 2010].

Из исходных изображений выделялись стандартные участки размером 150×150 пикселей, и именно они использовались для обучения и тестирования ИНС. Обучающая выборка содержала 20 000 изображений. Для проверки и тестирования использовалось по 8 000 изображений. Графики процесса обучения представлены на рис. 9 и 10. Как и в случае синтетических данных численного моделирования, варьировалось число эпох обучения с целью минимизации ошибки.

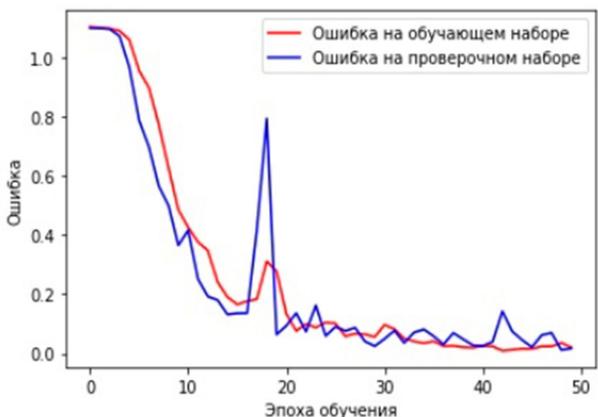


Рис. 9. График зависимости ошибки от количества эпох в процессе обучения на экспериментальных данных (для 50 эпох обучения)

Fig. 9. Graph of the error dependence on the number of epochs in the learning process based on experimental data (for 50 epochs of learning)

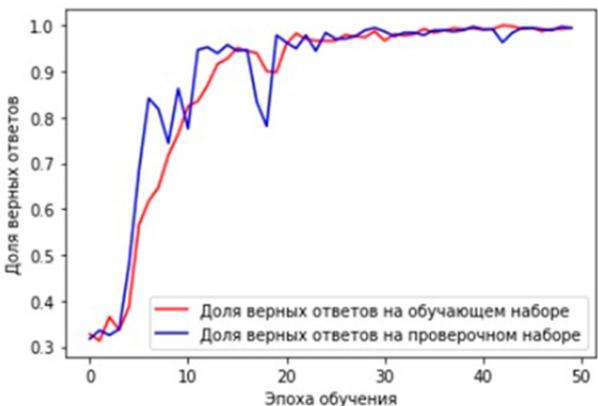


Рис. 10. График зависимости доли верных ответов от количества эпох в процессе обучения на экспериментальных данных (для 50 эпох обучения)

Fig. 10. Graph of the proportion of correct answers depending on the number of epochs in the learning process based on experimental data (for 50 epochs of learning)

В итоге обучения на экспериментальных данных, так же как и в случае синтетических изображений, при длительности 50 эпох была достигнута точность 97,8%. Из приведенных на рис. 10 графиков видно, что достигаемая при обучении точность не является монотонной функцией числа эпох.

Заключение

В ходе выполнения работы была опробована и верифицирована методика классификации режимов газожидкостного потока с помощью нейронных сетей сверточного типа.

Использовались два типа данных: 1) синтетические данные, полученные методами численного моделирования, и 2) реальные данные, полученные в ходе эксперимента на стенде многофазных потоков. При внешнем сходстве детальная структура синтетических изображений отличается от реальных прежде всего формой границы фаз. В обоих случаях ИНС успешно справляется с различием режимов потока.

Результаты исследования позволяют сделать вывод, что метод классификации режимов течения на основе визуального анализа его структуры с помощью обученных нейронных сетей обладает высокой точностью при достаточном объеме обучающей выборки и корректном алгоритме обучения.

Достигнутая точность 98,6% для данных численного моделирования и 97,8% для экспериментальных данных позволяет использовать ИНС сверточного типа в технических устройствах, предназначенных для определения и контроля режима течения.

СПИСОК ИСТОЧНИКОВ

- Бирюков Б. В., Данилов М. А., Кивилис С. С. 1987. Испытания расходомеров. М.: Изд-во стандартов. 240 с.
- Галушкин А. И., Цыпкин Я. З. 2015. Нейронные сети: история развития теории. М.: Альянс. 840 с.
- Ганопольский Р. М., Гильманов А. Я., Малыгин Г. А. 2020. Гидродинамическое моделирование потоков сложной формы. Тюмень: Изд-во Тюмен. гос. ун-та. 71 с.
- Гриценко А. И., Клапчук О. В., Харченко Ю. А. 1994. Гидродинамика газожидкостных смесей в скважинах и трубопроводах. М.: Недра. 238 с.
- Звонарев С. В. 2019. Основы математического моделирования: учеб. пос. Екатеринбург: Изд-во Урал. ун-та. 112 с.
- Мамаев В. А., Одишария Г. Э., Клапчук О. В., Точигин А. А., Семенов Н. И. 1978. Движение газожидкостных смесей в трубах. М.: Недра. 270 с.
- Плотникова И. Н. 2012. Элементный состав нефти и рассеянного органического вещества и методы его изучения: учеб.-метод. пос. Казань: Казан. ун-т. 25 с.
- Рид Р., Праусниц Дж., Шервуд Т. 1982. Свойства газов и жидкостей: пер. с англ. / под ред. Б. И. Соколова. 3-е изд., перераб. и доп. Л.: Химия, Ленингр. отд. 592 с.
- Уоллис Г. 1972. Одномерные двухфазные течения. М.: Мир. 440 с.
- Хайкин С. 2019. Нейронные сети. М.; СПб.: Диалектика. 1103 с.
- Цейтлин В. Г. 1977. Расходоизмерительная техника. М.: Изд-во стандартов. 240 с.
- Чисхолм Д. 1986. Двухфазные течения в трубопроводах и теплообменниках: пер. с англ. М.: Недра. 204 с.
- Ширяев В. И. 2016. Финансовые рынки. Нейронные сети, хаос и нелинейная динамика. М.: Либроком. 232 с.
- Boundary Conditions — OpenFOAM-4.1. 2017. NEXT foam. 132 p.
- Brill J. P., Mukherjee H. 1999. Multiphase Flow in Wells. Society of Petroleum Engineers. 164 p.
- Darwich T. D., Toral H., Archer J. S. 1991. A software technique for flow-rate measurement in horizontal two-phase flow // SPE Production Engineering. Vol. 6. No. 3. Pp. 265–270. <https://doi.org/10.2118/19510-PA>

- Pan S. J., Yang Q. 2010. A survey on transfer learning // *IEEE Transactions on Knowledge and Data Engineering*. Vol. 22. No. 10. Pp. 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
- State of the Art Multiphase Flow Metering. API Publication 2566. 2004. American Petroleum Institute. 80 p.
- Taitel Ye., Dukler A. E. 1976. A model for predicting flow regime transitions in horizontal and near horizontal gas-liquid flow // *AIChE Journal*. Vol. 22. No. 1. Pp. 47–55. <https://doi.org/10.1002/aic.690220105>

References

- Biryukov, B. V., Danilov, M. A., & Kivilis, S. S. (1987). *Testing of flowmeters*. Standards Publishing House. [In Russian]
- Galushkin, A. I., & Tsyppin, Ya. Z. (2015). *Neural networks: The history of theory development*. Alyans. [In Russian]
- Ganopolskij, R. M., Gilmanov, A. Ya., & Malygin, G. A. (2020). *Hydrodynamic modeling of flows of complex shape*. University of Tyumen Publishing House. [In Russian]
- Gritsenko, A. I., Klapchuk, O. V., & Kharchenko, Yu. A. (1994). *Hydrodynamics of gas-liquid mixtures in wells and pipelines*. Nedra. [In Russian]
- Zvonarev, S. V. (2019). *Fundamentals of mathematical modeling*. Ural University Publishing House. [In Russian]
- Mamaev, V. A., Odishariya, G. E., Klapchuk, O. V., Tochigin, A. A., & Semenov, N. I. (1978). *Movement of gas-liquid mixtures in pipes*. Nedra. [In Russian]
- Plotnikova, I. N. (2012). *Elemental composition of oil and dispersed organic matter and methods of its study*. Kazan University. [In Russian]
- Reid, R. C., Prausnitz, J. M., & Sherwood, T. K. (1977). *The properties of gases and liquids* (3rd ed.). McGraw-Hill.
- Wallis, G. (1972). *One-dimensional two-phase flows*. Mir. [In Russian]
- Haykin, S. (2019). *Neural networks*. Dialektika. [In Russian]
- Tsejtlin, V. G. (1977). *Flow measuring equipment*. Standards Publishing House. [In Russian]
- Chisholm, D. (1983). *Two-phase flow in pipe lines and heat exchanges*. Pitman Press.
- Shiryaev, V. I. (2016). *Financial markets. Neural networks, chaos and nonlinear dynamics*. Librokom. [In Russian]
- NEXT foam. (2017). *Boundary Conditions — OpenFOAM-4.1*.
- Brill, J. P., & Mukherjee, H. (1999). *Multiphase flow in wells*. Society of Petroleum Engineers.
- Darwich, T. D., Toral, H., & Archer, J. S. (1991). A software technique for flow-rate measurement in horizontal two-phase flow. *SPE Production Engineering*, 6(3), 265–270. <https://doi.org/10.2118/19510-PA>
- Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
- American Petroleum Institute. (2004). *State of the art multiphase flow metering*. API publication 2566.
- Taitel, Ye., & Dukler, A. E. (1976). A model for predicting flow regime transitions in horizontal and near horizontal gas-liquid flow. *AIChE Journal*, 22(1), 47–55. <https://doi.org/10.1002/aic.690220105>

Информация об авторах

Янис Валдисович Пурицкис, специалист, Тюменский нефтяной научный центр, Тюмень, Россия; студент магистратуры, Физико-технический институт, Тюменский государственный университет, Тюмень, Россия
yvpuritskis@tnnc.rosneft.ru

Владимир Евгеньевич Вершинин, главный специалист, Тюменский нефтяной научный центр, Тюмень, Россия; доцент кафедры моделирования физических процессов и систем, Физико-технический институт, Тюменский государственный университет, Тюмень, Россия
ve_vershinin2@tnnc.rosneft.ru

Information about the authors

Janis V. Puritskis, Specialist, Tyumen Petroleum Research Center, Tyumen, Russia; Master Student, Institute of Physics and Technology, University of Tyumen, Tyumen, Russia
yvpuritskis@tnnc.rosneft.ru

Vladimir E. Vershinin, Chief Specialist, Tyumen Petroleum Research Center, Tyumen, Russia; Associate Professor, Department of Physical Processes and Systems Modeling, Institute of Physics and Technology, University of Tyumen, Tyumen, Russia
ve_vershinin2@tnnc.rosneft.ru