

*Т. А. Янушенко<sup>1,2\*</sup>, Н. А. Голиков<sup>1,2,3</sup>*

## **Применение нейронных сетей в петрофизических исследованиях для определения фильтрационно-емкостных свойств**

<sup>1</sup> Новосибирский государственный университет, г. Новосибирск,  
Российская Федерация

<sup>2</sup> Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН,  
г. Новосибирск, Российская Федерация

<sup>3</sup> Новосибирский государственный технический университет, г. Новосибирск,  
Российская Федерация

\* e-mail: YanushenkoTA@ipgg.sbras.ru

**Аннотация.** С середины прошлого столетия с развитием представлений о структуре головного мозга активное развитие получили математические модели нейронных сетей. По мере совершенствования технологий и увеличения их доступности искусственные нейронные сети стали применяться во многих областях науки. Геофизика не стала исключением. В работе рассказывается, что такое искусственные нейронные сети, кратко описываются причины успеха использования их в геофизике, а также рассмотрены результаты последних работ по применению искусственных нейронных сетей для определения фильтрационно-емкостных свойств.

**Ключевые слова:** нейронные сети, фильтрационно-емкостные свойства

*T. A. Yanushenko<sup>1,2\*</sup>, N. A. Golikov<sup>1,2,3</sup>*

## **Application of neural networks in petrophysical researches to determine filtration and capacitance properties**

<sup>1</sup> Novosibirsk state university, Novosibirsk, Russian Federation

<sup>2</sup> Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, Novosibirsk, Russian Federation

<sup>3</sup> Novosibirsk State Technical University, Novosibirsk, Russian Federation

\* e-mail: YanushenkoTA@ipgg.sbras.ru

**Abstract.** Since the middle of the last century, with the development of ideas about the structure of the brain, mathematical models of neural networks have received active development. As technologies improved and their availability increased, the artificial neural networks began to be used in many fields of science. Geophysics was no exception. The paper explains that the artificial neural networks are, briefly describes the reasons for the success of their applying in geophysics, and also examines the results of recent work on the use of artificial neural networks to determine the filtration-capacitive properties.

**Keywords:** neural networks, filtration and capacitance properties

Основной научной задачей петрофизических исследований является установление связей между физическими, петрофизическими и литологическими

свойствами горных пород. Знание фильтрационно-емкостных свойств (ФЕС) коллекторов нефти и газа важно при количественных оценках запасов углеводородов нефтегазовых месторождений. Но часть существующих связей, например, таких как пористость-проницаемость, носит эмпирический характер и отличается от скважины к скважине, либо имеет нетривиальный нелинейный вид [1].

В середине прошлого века, после получения представлений о структуре мозга, как огромного количества нейронов связанных друг с другом, были предложены первые математические модели, ставшие в последующем основанием для создания искусственных нейронных сетей. Дальнейшая интеграция в различные области науки, а также совершенствование и распространение технических возможностей, позволили использовать искусственные нейронные сети для решения задач различного направления [2].

Искусственные нейронные сети (ИНС) – вычислительные системы или математические модели (а также их программные или аппаратные реализации), предназначенные для моделирования принципов работы биологической нервной системы с использованием многочисленных взаимосвязанных нейронов [2-3]. Пример простой искусственной нейронной сети представлен на рис. 1.




Рис. 5. Схема искусственной нейронной сети [4]

Согласно [4], ИНС делятся на сети прямого распространения сигнала и на рекуррентные. Последние, в отличие от первых, допускают использование циклов в своей структуре. Важной составляющей процесса создания ИНС является ее обучение. В условиях этого параметра ИНС можно разделить на 3 группы – обучение с учителем, обучение без учителя и обучение с подкреплением. Согласно [3-4], в большинстве геофизических задач используется первый тип обучения.

Преимуществами ИНС для геофизических исследований являются отсутствие ограничения на линейность задачи и эффективность в условиях шумов. Помимо этого, для обучения ИНС, то есть получения весов для каждого из соеди-

нений нейронов, необходимо обучающее множество, что вполне возможно обеспечить с тем большим количеством данных, которое получают в процессе измерений и геологических изысканий. Поэтому обучение с учителем является самым распространенным в этой области. Но в то же время, специфичность исследований в разных местах и отсутствие конструктивного подхода создания ИНС с заранее заданными параметрами не всегда позволяют унифицировать их в области геологии и геофизики. [2, 4-5]

В геофизике существует огромное множество задач. Так в [6] предлагается разделить задачи на следующие группы:

- 1) Моделирование [7];
- 2) Пространственное предсказание [8-9]:
  - a. Инверсии;
  - b. Реконструкции;
- 3) Временное предсказание [10]:
  - a. «Прямой» прогноз;
  - b. «Обратный» прогноз;
- 4) Детектирование (например, землетрясений) [11-12];
- 5) Классификация [13].

Для каждой из групп проводятся исследования применения ИНС для решения какой-либо поставленной задачи. Для обучения ИНС чаще всего использовали алгоритм обратного распространения ошибки, основанный на методе градиентного спуска [4, 14]. Авторы отмечают перспективность использования данного подхода в будущих работах и в геофизике в целом.

В петрофизических исследованиях для определения ФЕС – пористости, проницаемости и насыщенности – ИНС тоже используются. Это помогает минимизировать затраченное время на исследования керн и получать результат в короткое время. Так в [3] приводится статистика использования данного подхода в работах до 2020 года. Чаще всего ИНС применяют для определения пористости и проницаемости, так как существуют нелинейные связи между этими параметрами и другими свойствами пород [15]. Ярким примером такого использования может послужить исследование коэффициента насыщенности, который в стандартных условиях ищут при помощи уравнения Арчи. ИНС позволяет подобрать коэффициенты этого уравнения на основании литологии и степени цементации исследуемых пород [16].

В последних работах можно встретить различные применения ИНС для прогнозирования ФЕС. Так, в работе [17] проводилось исследование возможности определения пористости на основании сейсмических данных. В выводах автор указывает, что корреляция предсказанных значений и реальных составляет 0.7, что мало для использования метода, как самостоятельного, но достаточно, чтобы использовать его в качестве вспомогательного. В [18] показана применимость ИНС для карбонатных коллекторов сразу для нескольких скважин, но с пониженным качеством предсказания. В работах [19-20] достигнуты хорошие результаты по предсказанию коэффициента пористости.

Небольшая часть работ посвящена оценке проницаемости горных пород при помощи ИНС в России. Например, в [21] модели основываются на данных ГИС: абсолютной глубине, естественной радиоактивности, плотности, нейтронном каротаже и акустическом времени. В работах [22-24] проницаемость предсказывается как на основании фотографий шлифов или 3D моделей керна, так и на данных каротажа. При этом, в [22] показывается применимость к фотографиям плохого качества, что актуально в условиях прикладных наук.

В [25] коэффициент водонасыщенности находят применением ИНС к инверсии данных электромагнитного зондирования в скважине. Ошибка прогноза составила 20-25%, что сравнимо с ошибкой определения в лабораторных условиях. Результаты исследования, приведенные в [26], показывают успешное использование ИНС, принимающий на вход 9 параметров, получаемых в процессе каротажа. Точность определения коэффициента водонасыщенности достигла 97-98%. В то же время, в работе [27] показана возможность использования маленького количества входных данных для предсказания коэффициента пористости, но в то же время доказала невозможность определения коэффициента насыщенности.

Помимо этого, ИНС успешно применяют для оценки параметров, тесно связанных с ФЕС. В работе [28] с хорошей точностью предсказывают коэффициент цементации. В [29-30] ИНС применяются для решения задач классификации на основе данных шлифов и керна.

Большие перспективы имеют ИНС для оценки параметров структуры порового пространства, изучаемыми одним методом на основе применения других методов. Например, в работе [31] показана возможность применения ИНС для ЯМР-кривой при инверсии многоэкспоненциального спада, что упрощает процесс математической обработки и делает распределения времен поперечной релаксации более точными и «гибкими» по отношению к параметрам. В [32] ИНС используют для оценки распределения пор на основании данных ЯМР, ртутной порометрии и петрофизических данных. Метод ЯМР позволяет получать информацию о распределении пор по размеру, оценивать индексы свободного и связанного флюида. Применение же ИНС к результатам этих измерений и использование априорной информации о литологии или других параметрах позволит с высокой точностью оценивать ФЕС не только традиционных коллекторов, но и нетрадиционных, мелкопористых и малопроницаемых коллекторов.

### *Заключение*

1. Наиболее часто ИНС применяются для оценки пористости и проницаемости по данным геофизических и литологических измерений.
2. Для оценки остальных петрофизических параметров (Кв, классификации коллекторов и др.) применение ИНС находится на начальном этапе.
3. Особый интерес представляет применение ИНС для предсказания свойств коллектора по данным, связанным со структурой порового пространства коллектора (порометрия, данные ЯМР-релаксометрии).

Таким образом, разнообразие и количество работ показывает актуальность и перспективность использования ИНС не только для определения ФЭС, но и для других параметров. В то же время, авторы отмечают недостатки в полученной точности своих исследований. Понимание данной проблемы и желание ее решить, а также большое значение прикладного направления, обеспечивают перспективность развития данной области.

#### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Доналдсон Э., Тиаб Д. Петрофизика: теория и практика изучения коллекторских свойств горных пород и движения пластовых флюидов / пер. Углов М.Д., под ред. Петерсилье В.И., Былевского Г.А. – М.: ООО «Премиум Инжиниринг», 2009. – 840 с.
2. Горбачевская Е.Н., Краснов С.С. История развития нейронных сетей // Вестник Волжского университета им. В.Н. Татищева. – 2015. – № 1(23). – С. 52-56.
3. Okon, A. N., Adewole, S. E., Uguma, E. M. Artificial neural network model for reservoir petrophysical properties: porosity, permeability and water saturation prediction. *Modeling Earth Systems and Environment // Modeling Earth Systems and Environment*. — 2021. — Т. 7. — № 12 — С. 2073-2390.
4. Созыкин А. В. Обзор методов обучения глубоких нейронных сетей // Вестник Южно-Уральского государственного университета. Серия: Вычислительная математика и информатика. – 2017. – Т. 6. – № 3. – С. 28-59.
5. Gevorkyan M. N., et al. Review and comparative analysis of machine learning libraries for machine learning // *Discrete and Continuous Models and Applied Computational Science*. – 2019. – Vol. 27. – №. 4. – P. 305-315.
6. Yu S., Ma J. Deep Learning for Geophysics: Current and Future Trends // *Reviews of Geophysics*. – 2021. – Vol. 59. – № 3. – P. 1-36.
7. Хайретдинов М. С., и др. Восстановление геофизических моделей упругих сред с применением нейронных сетей // *Проблемы информатики*. – 2020. – Т. 48. – № 3. – С. 60-69.
8. Спичак В. В. Современные методы комплексного анализа и инверсии геофизических данных // *Геология и геофизика*. – 2020. – Т. 61. – № 3. – С. 422-443.
9. Оборнев Е. А. и др. Применение нейронных сетей в нелинейных обратных задачах геофизики // *Журнал вычислительной математики и математической физики*. – 2020. – Т. 60. – № 6. – С. 1053-1065.
10. Ge C. et al. Tectonic discrimination and application based on convolution neural network and incomplete big data // *Journal of Geochemical Exploration*. – 2021. – Vol. 220. – P. 1-10.
11. Ульянов Н.А., и др. Детекция записей слабых локальных землетрясений с использованием нейронных сетей // *Геофизические технологии*. – 2021. – № 2. – С. 13-23.
12. Jozinović D., et al. Transfer learning: improving neural network based prediction of earthquake ground shaking for an area with insufficient training data // *Geophysical Journal International*. – 2022. – Vol. 229. – № 1. – P. 704–718.
13. Lu G. et al. Lithology identification using graph neural network in continental shale oil reservoirs: A case study in Mahu Sag, Junggar Basin, Western China // *Marine and Petroleum Geology*. – 2023. – Vol. 150. – P. 1-19.
14. Toms B.A., Barnes E.A., Ebert-Uphoff I. Physically Interpretable Neural Networks for the Geosciences: Applications to Earth System Variability // *Journal of Advances in Modeling Earth Systems*. – 2020, Vol. 12. - № 9. – P.1-20.
15. Wood D.A. Predicting porosity, permeability and water saturation applying an optimized nearest-neighbour, machine-learning and data-mining network of well-log data // *Journal of Petroleum Science and Engineering*. – 2020. – Vol. 184. – P. 1-17.

16. Al-Bulushi N. et al. Development of artificial neural network models for predicting water saturation and fluid distribution // *Journal of Petroleum Science and Engineering*. – 2009. – Vol. 68. – № 3. – P. 197–208.
17. Применение нейронных сетей в Python для исследования пористости по скважинам на основании сейсмических данных / Тимофеева А. А. // *Актуальные проблемы недропользования: тезисы докладов участников XIX Международного форума-конкурса студентов и молодых ученых, Санкт-Петербург, 21–27 мая, 2023*. – Санкт-Петербург: Санкт-Петербургский горный университет, 2023. – С. 326-331.
18. Прогноз пористости в карбонатных коллекторах методами машинного обучения / Г. В. Шиверский, С. Н. Кривошеков // *Геология в развивающемся мире: Сборник научных трудов по материалам XVI Международной научно-практической конференции студентов, аспирантов и молодых ученых Пермь, Пермь, 13–14 апреля, 2023*. – Пермь: Пермский государственный национальный исследовательский университет, 2023. – С. 241-245.
19. Al-AbdulJabbar A. et al. Estimation of Reservoir Porosity from Drilling Parameters Using Artificial Neural Networks // *Petrophysics*. – 2020. – Vol. 61. – P.318–330.
20. Feng R. Estimation of reservoir porosity based on seismic inversion results using deep learning methods // *Journal of Natural Gas Science and Engineering*. – 2020. – Vol. 77. – P. 1-9.
21. Прогноз проницаемости нижнепермского карбонатного пласта I Приразломного м/я на основе гидравлических единиц потока методами машинного обучения / Караченцев В. В. и др. // *Геомодель 2022: Сборник материалов 24-й научно-практической конференции по вопросам геологоразведки и разработки месторождений нефти и газа, Геленджик, 05–08 сентября, 2022*. – Москва, 2022. – С. 452-455.
22. Zhang H. et al. Permeability prediction of low-resolution porous media images using auto-encoder-based convolutional neural network // *Journal of Petroleum Science and Engineering*. – 2022. – Vol. 208. – P. 1-14.
23. Urang J.G. et al. A new approach for porosity and permeability prediction from well logs using artificial neural network and curve fitting techniques: A case study of Niger Delta, Nigeria // *Journal of Applied Geophysics*. – 2020. – Vol. 183. – P. 1-14.
24. Tang P., Zhang D., Li H. Predicting permeability from 3D rock images based on CNN with physical information // *Journal of Hydrology*. – 2022. – Vol. 606. – P. 1-13.
25. Spichak V.V., Goidina A.G., Zakharova O.K. Porosity and water saturation predicting beyond boreholes from electromagnetic sounding and core sample data: Soultz-sous-Forêts (France) case study // *Journal of Applied Geophysics*. – 2023. – Vol. 212. – P. 1-10.
26. Azim R.A., Hamada G. Novel Correlation for Calculating Water Saturation in Shaly Sandstone Reservoirs Using Artificial Intelligence: Case Study from Egyptian Oil Fields // *ACS Omega*. – 2022. – Vol. 7. – № 34. – P. 29666-29674.
27. Применение алгоритма «Случайный лес» при предсказании коэффициента пористости и коэффициента нефтенасыщенности при интерпретации данных со-каротажа / Гильмутдинов А.И. // *Энергия молодежи для нефтегазовой индустрии: Сборник материалов V Международной научно-практической конференции молодых ученых, Альметьевск, 13 ноября, 2020*. – Альметьевск: Альметьевский государственный нефтяной институт, 2020. – С. 653-658.
28. Mahmoodpour S. et al. Prediction of cementation factor for low-permeability Iranian carbonate reservoirs using particle swarm optimization-artificial neural network model and genetic programming algorithm // *Journal of Petroleum Science and Engineering*. – Vol. 197. – P. 1-13.
29. Попов Н.А. и др. Применение технологий глубокого обучения для изучения шлифов на примере Усинского месторождения нефти // *Известия Томского политехнического университета. Инжиниринг георесурсов*. – 2020. – Т. 331. – № 6. – С. 100-112.
30. Елишева О.В. и др. Типизация пород доюрского основания по керну и прогноз вещественного состава с помощью нейросетевого моделирования на основе карт Кохонена // *Известия высших учебных заведений. Нефть и газ*. – 2022. – Т. 155. - № 5. – С. 14-35.

31. Luo G. et al. A study on multi-exponential inversion of nuclear magnetic resonance relaxation data using deep learning // *Journal of Magnetic Resonance*. – 2023. – Vol. 346. – P. 1-9.
32. Zhou Y. et al. Determination of pore size distribution in tight gas sandstones based on Bayesian regularization neural network with MICP, NMR and petrophysical logs // *Journal of Natural Gas Science and Engineering*. – 2022. – Vol. 100. – P. 1-13.

© *T. A. Янушенко, Н. А. Голиков, 2024*