ОБЗОР ПРИМЕНЕНИЯ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ В ГЕОФИЗИКЕ И ЗАДАЧАХ МОНИТОРИНГА

Суржик Д.И. д.т.н,

Махотин В.Р., аспирант,

НИИ БелГУ, г. Белгород, Россия

Аннотация. В обзоре рассматривается применение искусственных нейронных сетей в геофизике и задачах геоэкологического мониторинга. Показано, что фундаментальная нелинейность, некорректность и многомерность геофизических обратных задач делают нейросетевые аппроксимационные методы особенно эффективными по сравнению с классическими оптимизационными подходами. Рассмотрены нейросетевые методы прогнозирования временных рядов деформаций земной поверхности по данным радарной интерферометрии и комплексной интерпретации мультиметодных геофизических данных. Отдельное внимание уделено архитектурам нейронных сетей, предназначенным для разделения смешанных сигналов от нескольких одновременно действующих источников геодинамической активности: автоэнкодерам, разрежённым и вариационным автоэнкодерам, генеративно–состязательным сетям, трансформерам, физически информированным сетям, неотрицательной матричной факторизации, рекуррентным нейронным сетям и ограниченным машинам Больцмана. Показано, что классические статистические методы разделения ограничены предположениями о линейности, стационарности и гауссовости смешивания, тогда как нейросетевые архитектуры преодолевают эти ограничения. Проведён критический анализ преимуществ и ограничений глубокого обучения по сравнению с традиционными

методами. Обосновано, что наиболее перспективным направлением является гибридизация физически информированных и data–driven подходов, при которой нейросеть не заменяет физику, а дополняет её, используя физические уравнения как ограничения и обеспечивая скорость и гибкость, недоступные классическим методам.

Ключевые слова: геофизика, нейросетевые технологии, архитектура нейросетей, обратные задачи геофизики, географические данные, ИНС, MLP, InSAR.

Искусственные нейронные сети (ИНС) – вычислительные системы, моделирующие принципы работы биологической нервной системы посредством множества взаимосвязанных искусственных нейронов – начали проникать в геофизику с 1990–х годов. Фундаментальная причина их успеха заключается в том, что геофизические обратные задачи по своей природе являются нелинейными, некорректно поставленными и многомерными, а нейросети представляют собой мощный аппарат аппроксимации сложных нелинейных зависимостей, обоснованный теоремами Колмогорова, Вейерштрасса–Стоуна и Цыбенко [1; 2]. Принципиальные преимущества ИНС для геофизических исследований: отсутствие ограничения на линейность задачи, эффективность в условиях зашумлённых данных, способность к обобщению и возможность работы в режиме реального времени после завершения обучения [1; 2].

Нейросетевые методы в решении обратных задач геофизики

Классический подход, развиваемый с 1990–х годов, – аппроксимационный нейросетевой (АНС) метод. Его суть: построение приближённого обратного оператора задачи с помощью многослойных персептронов (MLP) на основе заранее построенного множества опорных решений прямых и обратных задач. Если обратная задача сводится к нелинейному операторному уравнению I рода $d = A(m)$, где d – данные наблюдений, m – вектор модельных параметров, A – оператор прямой задачи, то АНС–метод строит приближённый обратный оператор в виде $m = MLP(d; W)$, где W – веса сети,

настраиваемые в процессе обучения на множестве пар (d_i, m_i), сгенерированных путём многократного решения прямой задачи для различных моделей среды [1; 2]. Достигнутые результаты: построение универсальных нейросетевых аппроксиматоров инверсии, способных устойчиво решать нелинейные обратные задачи в конечно–параметрических классах сред с числом искомых параметров 2D– и 3D–сред порядка 10^3 за первые секунды – фактически в режиме реального времени, с приемлемой для практики точностью [1; 2].

Применение в геоэлектрике, гравиметрии и магнитометрии

В геоэлектрике нейросетевой подход применяется для одномерной инверсии вертикального электрического зондирования (ВЭЗ), классификации неоднородных слоёв с частотной дисперсией электропроводности в магнитотеллурических зондированиях [1], решения коэффициентной обратной 2D–задачи методом глубокого обучения с применением свёрточных нейронных сетей (CNN) архитектуры U–Net [3]. В гравиметрии и магнитометрии MLP–сети применяются для построения карт гравитационных аномалий, комплексной инверсии данных магнито– и гравиразведки, кластерного анализа площадных геофизических данных с выделением геологических структур различного порядка [1]. АНС–метод без существенных изменений применяется для решения многокритериальных (мультиметодных) задач, где несколько геофизических полей инвертируются одновременно, что принципиально снижает неоднозначность по сравнению с раздельной инверсией [1; 2].

Нейросетевые технологии в сейсморазведке

Сейсмическая инверсия – преобразование записанных сейсмических трасс в физически значимые параметры среды (акустический импеданс, плотность, скорости) – является одной из наиболее активно развивающихся областей применения глубокого обучения в

геофизике [4; 5]. Свёрточные нейронные сети (CNN) для инверсии акустического импеданса не требуют извлечения сейсмического импульса и построения низкочастотной модели [4; 5]. Архитектура Attention U–Net для многоканальной инверсии использует пространственную корреляцию сейсмических данных; модуль внимания подавляет нерелевантные области во входных данных [4]. Генеративно–состязательные сети (GAN) на основе архитектуры Трансформер с методом semi–supervised learning показали результаты, сопоставимые с алгоритмом model–based инверсии, при значительном сокращении времени [5]. Полноволновая инверсия (FWI) может быть представлена как рекуррентная нейронная сеть и реализована с использованием программного обеспечения глубокого обучения [6]. Фундаментальное различие: геофизическая инверсия использует явный прямой оператор, а машинное обучение не использует его явно, оперируя парами вход–выход. Преимущество ML – повышенное разрешение, так как нейросеть восстанавливает высокочастотные компоненты, утраченные при свёртке с сейсмическим импульсом [4; 5]. Ограничение – при недостатке размеченных данных классическое обучение приводит к переобучению [5].

Нейросети в петрофизике и интерпретации каротажа

ИНС применяются для определения пористости, проницаемости и насыщенности по данным геофизических исследований скважин (ГИС), минимизируя время на исследования керна [7]. Для прогнозирования литологии применяются одномерные CNN, обученные с использованием алгоритмов оптимизации Adagrad, Adadelta, Adamax [8]. Для классификации фаций используются двунаправленные рекуррентные сети BLSTM, способные учитывать чередование фаций в обоих направлениях по скважине [9]. Распознавание пород многослойным персептроном обеспечивает корректное решение нефтепоисковых задач с вероятностью более 98% против 54% при традиционных методах [10].

Нейросети в геодинамическом мониторинге и InSAR

Рекуррентная нейронная сеть LSTM является доминирующей архитектурой для прогнозирования временных рядов деформаций поверхности, полученных методами радарной интерферометрии; модифицированная архитектура mLSTM обеспечивает более высокую точность прогноза деформаций по данным спутниковых интерферометрических наблюдений, чем базовый LSTM и RNN [11]. Гибридная модель DBO–CNN–LSTM, сочетающая оптимизацию на основе алгоритма навозного жука [13], свёрточную сеть для извлечения пространственных признаков и LSTM для временного анализа, применяется для высокоточного мониторинга и прогнозирования деформаций поверхности закрытых шахт по данным SBAS–InSAR [12]. CNN применяются для автоматической детекции деформаций в национальных масштабах по спутниковым интерферометрическим данным; вместе с тем отмечено, что CNN не позволяет детектировать очень локализованные деформации, пространственные характеристики которых близки к шуму [14]. Перспективное направление – физически–информированные модели глубокого обучения, интегрирующие геофизические и геотехнические принципы непосредственно в процесс обучения [11; 14].

Архитектуры нейросетевых технологий для разделения смешанных сигналов

В геофизике и геоэкологическом мониторинге наблюдаемые поля часто представляют собой сумму откликов от нескольких одновременно действующих источников разной физической природы. Классические статистические методы разделения – анализ независимых компонент (ICA), анализ главных компонент (PCA), неотрицательная матричная факторизация (NMF) – ограничены предположениями о линейности смешивания, стационарности и гауссовости распределений. Нейросетевые архитектуры преодолевают эти ограничения.

Автоэнкодеры архитектуры «узкое горлышко» сжимают входной вектор наблюдений в

латентное пространство пониженной размерности и восстанавливают его; вариационный автоэнкодер (VAE) включает KL–дивергенцию для обеспечения независимого распределения латентных переменных и позволяет автоматически определять число активных источников в смеси [15]. Разрежённые автоэнкодеры добавляют L1–регуляризацию, обнуляющую вклады отсутствующих источников [16].

Генеративно–состязательные сети (GAN–BSS) используют состязательную тренировку: генератор отображает наблюдения в компоненты, дискриминатор оценивает их реалистичность [17]. Базовая рекуррентная нейронная сеть (RNN) применяется для потокового разделения в реальном времени; архитектуры LSTM и GRU решают проблему затухающего градиента [18; 19]. Физически информированные сети (PINN–BSS) встраивают физические уравнения в функцию потерь, что резко сужает пространство допустимых решений и позволяет работать при малом объёме обучающих данных [20].

Глубокое обучение против традиционных методов: критический анализ

Преимущества глубокого обучения: скорость инференса (секунды против часов), повышенное разрешение, отсутствие ограничения на линейность модели, робастность к шуму при достаточном объёме обучающей выборки [1; 4; 5]. Ограничения: эффект «чёрного ящика», дефицит размеченных данных, проблема обобщения, неучёт физики в чисто data–driven подходе, чувствительность некоторых архитектур к шуму, неспособность CNN детектировать очень локализованные деформации на картах InSAR [11; 14].

Наиболее перспективное направление – гибридизация физически–информированных и data–driven подходов. Физически–информированные ИНС (PINN) встраивают дифференциальные уравнения непосредственно в функцию потерь и эффективны при решении как прямых, так и обратных задач [20].

Заключение

Нейросетевые технологии за тридцать лет прошли путь от лабораторных экспериментов с простыми персептронами до промышленных систем сейсмической инверсии на основе архитектур U–Net, Transformer и GAN [4; 5]. Геофизика оказалась одной из наиболее благоприятных областей для применения ИНС благодаря принципиальной нелинейности обратных задач, большим объёмам данных и потребности в работе в режиме реального времени [1; 2]. Ключевой вызов остаётся неизменным: чисто data–driven подход не способен гарантировать физическую корректность и интерпретируемость результатов. Будущее – за гибридными физически–информированными моделями, в которых нейросеть не заменяет физику, а дополняет её, используя физические уравнения как ограничения и обеспечивая скорость и гибкость, недоступные классическим оптимизационным методам [20].

Литература

1. Применение нейронных сетей в нелинейных обратных задачах геофизики / Е. А. Оборнев [и др.] // Журнал вычислительной математики и математической физики. – 2020. – Т. 60, № 6. – С. 1053–1065. – DOI 10.31857/S0044466920060071.

2. Аппроксимационный нейросетевой метод решения многомерных нелинейных

обратных задач геофизики / М. И. Шимелевич [и др.] // Физика Земли. – 2017. – № 4. – С. 100–109. – DOI 10.7868/S0002333717040093.

3. MT2DInv-Unet: A two-dimensional magnetotelluric inversion method based on deep learning technology [Электронный ресурс] / K. Pan [и др.] // Geophysics. – 2024. – Т. 89, № 2. – C . G13–G27. – DOI 10.1190/geo2023-0004.1. – URL: https://doi.org/10.1190/geo2023-0004.1 (дата обращения : 10.11.2026).

4. Multichannel seismic impedance inversion based on Attention U-Net [Электронный ресу рс] / J. Ning [и др .] // Frontiers in Earth Science. – 2023. – T . 11. – Ст . 1104488. – DOI 10.3389/feart.2023.1104488. – URL: https://doi.org/10.3389/feart.2023.1104488 (дата обращения : 10.11.2026).

5. Применение генеративносостязательных нейронных сетей на основе трансформеров в качестве алгоритма для сейсмической амплитудной инверсии [Электронный ресурс] / В. Д. Гришко [и др.] // PROНЕФТЬ. Профессионально о нефти. – 2025. – Т. 10, № 1. – С. 146–155. – DOI 10.51890/2587-7399-2025-10-1-146-155. – URL: https://proneft.elpub.ru/jour/article/view/552 (дата обращения: 10.11.2026).

6. Richardson A. Seismic full-waveform inversion using deep learning tools and techniques [Электронный ресурс] : препринт

. – 2018. – arXiv:1801.07232. – URL: https://arxiv.org/abs/1801.07232 (
дата
обращения
: 10.11.2026).

7. Artificial neural network model for reservoir petrophysical properties: porosity, permeability and water saturation prediction / A. N. Okon, S. E. Adewole, E. M. Uguma [Электронный ресурс
] // Modeling Earth Systems and Environment. – 2021. –
T
. 7, № 4. –
C
. 2373–2390. – DOI 10.1007/s40808-020-01012-4. – URL:
https://doi.org/10.1007/s40808-020-01012-4 (
дата
обращения
: 10.11.2026).

8. Lithological facies classification using deep convolutional neural network / Y. Imamverdiyev, L. Sukhostat [Электронный ресурс] // Journal of Petroleum Science and Engineering. – 2019. – Т. 174. – С. 216–228. – DOI 10.1016/j.petrol.2018.11.023. – URL:
https://doi.org/10.1016/j.petrol.2018.11.023 (
дата
обращения
: 10.11.2026).

9. Tight sandstone reservoir classification based on 1DCNN-BLSTM with conventional logging data [Электронный ресурс] / Y. Wang [и др.] // Acta Geophysica. – 2025. – Т. 73, № 3. –
C
. 2373–2389. – DOI 10.1007/s11600-024-01506-0. – URL:
https://doi.org/10.1007/s11600-024-01506-0 (
дата
обращения
: 10.11.2026).

10. Применение нейросетевого подхода при интерпретации каротажных данных /

С. Н. Родина, К. Ю. Силкин [Электронный ресурс] // Вестник Воронежского государственного университета. Серия: Геология. – 2007. – № 2. – С. 184–188. – URL: http://www.vestnik.vsu.ru/pdf/heologia/2007/02/2007-02-18.pdf (дата обращения: 10.11.2026).

11. Prediction of InSAR deformation time-series using improved LSTM deep learning model / R. Soni, M. S. Alam, G. K. Vishwakarma [Электронный ресурс] // Scientific Reports. – 2025. – Т. 15. – Ст. 5333. – DOI 10.1038/s41598-024-83084-1. – URL: https://doi.org/10.1038/s41598-024-83084-1 (дата обращения : 10.11.2026).

12. High-precision temporal monitoring and prediction of surface deformation at closed mines using time series InSAR and the deep learning DBO-CNN-LSTM model [Электронный ресурс] / J. Luo [и др .] // Natural Resources Research. – 2026. – Т. 35. – С. 607–627. – DOI 10.1007/s11053-025-10569-9. – URL: https://doi.org/10.1007/s11053-025-10569-9 (дата обращения : 10.11.2026).

13. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization / J. Xue, B. Shen [Электронный ресурс] // The Journal of Supercomputing. – 2023. – Т. 79, № 7. – С. 7305–7336. – DOI 10.1007/s11227-022-04959-6. – URL: https://doi.org/10.1007/s11227-022-04959-6 (

дата
обращения
: 10.11.2026).

14. Detecting ground deformation in the built environment using sparse satellite InSAR data with a convolutional neural network [Электронный ресурс] / N. Anantrasirichai [и д
р
.
] // IEEE Transactions on Geoscience and Remote Sensing. – 2021. –
Т
. 59, № 4. –
С
. 2940–2950. – DOI 10.1109/TGRS.2020.3018315. – URL:
https://doi.org/10.1109/TGRS.2020.3018315 (
дата
обращения
: 10.11.2026).

15. Unsupervised blind source separation with variational auto-encoders / J. Neri, R. Badeau, P. Depalle [Электронный ресурс] // Proceedings of the 29th European Signal Processing Conference (EUSIPCO). – Dublin, 2021. –
С
. 311–315. – DOI 10.23919/EUSIPCO54536.2021.9616154. – URL:
https://doi.org/10.23919/EUSIPCO54536.2021.9616154 (
дата
обращения
: 10.11.2026).

16. Dabin J. A. One-stage blind source separation via a sparse autoencoder framework [Электронный ресурс] : дис. … PhD. – Newark : New Jersey Institute of Technology, 2022. – URL: https://digitalcommons.njit.edu/dissertations/1600/ (
дата
обращения
: 10.11.2026).

17. Generative adversarial source separation / Y. C. Subakan, P. Smaragdis [Электрон
ный ресу
рс] //

Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). – Calgary, 2018. –
С
. 26–30. – DOI 10.1109/ICASSP.2018.8461671. – URL:
https://doi.org/10.1109/ICASSP.2018.8461671 (
дата
обращения
: 10.11.2026).

18. Long short-term memory / S. Hochreiter, J. Schmidhuber [Электронный ресурс] // Neural Computation. – 1997. –
Т
. 9, № 8. –
С
. 1735–1780. – DOI 10.1162/neco.1997.9.8.1735. – URL:
https://doi.org/10.1162/neco.1997.9.8.1735 (
дата
обращения
: 10.11.2026).

19. Learning phrase representations using RNN encoder-decoder for statistical machine translation [Электронный ресурс] / K. Cho [и др.] : препринт. – 2014. –
arXiv:1406.1078. – URL: https://arxiv.org/abs/1406.1078 (
дата
обращения
: 10.11.2026).

20. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations / M. Raissi, P. Perdikaris, G. E. Karniadakis [Электронный ресурс] // Journal of Computational Physics. – 2019. – Т. 378. – С. 686–707. – DOI 10.1016/j.jcp.2018.10.045. – URL: https://doi.org/10.1016/j.jcp.2018.10.045 (
дата
обращения
: 10.11.2026).