



УДК 550.31, 004.89

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПОСТРОЕНИЯ СТРУКТУРНЫХ ГРАНИЦ РАЗРЕЗА ПО ПОТЕНЦИАЛЬНЫМ ПОЛЯМ

А.Д. Шклярчук¹, К.М. Кузнецов¹¹Московский государственный университет имени М.В. Ломоносова, Москва, Россия

В статье рассмотрены подходы по восстановлению границ слоев контрастных по плотностным и магнитным свойствам на основе машинного обучения. В работе продемонстрированы алгоритмы на основе многослойных нейронных сетей прямого распространения для решения задачи восстановления структурных границ по потенциальным полям. Для их обучения предлагается использовать либо профили, либо области с уже известным положением искомой границы. Подход основан на построении регрессионных зависимостей между гравитационными и магнитными полями, а также их трансформантами и отражающими горизонтами, определенными, например, по результатам интерпретации данных сейсморазведки.

КЛЮЧЕВЫЕ СЛОВА: МАШИННОЕ ОБУЧЕНИЕ, НЕЙРОННЫЕ СЕТИ, СТРУКТУРНЫЕ ГОРИЗОНТЫ, КОМПЛЕКСИРОВАНИЕ ГЕОФИЗИЧЕСКИХ МЕТОДОВ, ГРАВИРАЗВЕДКА, МАГНИТОРАЗВЕДКА, ГЕОЛОГО-ГЕОФИЗИЧЕСКИЕ МОДЕЛИ

DOI 10.5425/2304-7380_2022_38_18

<https://elibrary.ru/qkycjy>

1. ВВЕДЕНИЕ

На этапе мелко и среднемасштабных геолого-геофизических исследований помимо сейсморазведки активно применяются методы потенциальных полей (гравиразведка и магниторазведка), которые в отличие от профильных сейсмических наблюдений с учетом современных спутниковых и авиационных технологий обеспечивают качественную площадную плотностную и магнитную характеристику района исследования. К основным задачам, стоящим перед гравиразведкой и магниторазведкой, относится задача по построению площадных моделей границ разреза, которые разделяют контрастные по плотности или намагнитченности слои. Среди большого числа алгоритмических решений наиболее эффективными являются методы, использующие комплексный подход, в которых в качестве эталона используются результаты интерпретации сейсморазведки с информацией о морфологии отражающих горизонтов. Важным при решении данных задач является учет максимального объема имеющейся априорной информации, к которой можно отнести положение нецелевых границ разреза, например, таких как граница Мохоровичича, подошва осадочного чехла, а также дневной рельеф или рельеф морского дна и др.

Восстановление морфологии структурной поверхности по геолого-геофизическим данным возможно рассмотреть, как задачу поиска зависимости между входной информацией, которая в первую очередь включает геопотенциальные поля, а также иные геофизические и геологические данные, и

Электронная почта авторов для переписки:

Шклярчук Алексей Дмитриевич, e-mail: alexsh9898@yandex.ru
Кузнецов Кирилл Михайлович, e-mail: kuznetsovkm@my.msu.ruАдрес редакции журнала
«Гелиогеофизические исследования»:ФГБУ «ИПГ»
129128; Россия, Москва
ул. Ростокинская, 9.
e-mail: vestnik@ipg.geospace.ru<https://elibrary.ru/qkycjy>

искомой поверхностью. Для оценки зависимости предлагается использовать эталонные участки, то есть те, на которых представлены как входные, так и выходные данные. В настоящее время одним из активно развивающихся направлений является машинное обучение, в рамках которого такого рода задачи относятся к классу задач регрессии.

Зависимость между аномальными гравитационными и магнитными полями и восстанавливаемой границей может быть представлена различным образом:

- линейной, нелинейной или множественной регрессией [1];
- нелинейной регрессией, описываемой с помощью Гауссовского процесса;
- «деревом решений» или каскадом таких деревьев («случайный лес») [2];
- различными по своей архитектуре нейронными сетями [3].

Стоит отметить, что регрессии, представляемые различными аналитическими выражениями, не всегда позволяют описать сложные функциональные связи между входными и выходными данными в поставленной задаче.

2. СРАВНЕНИЕ РАЗЛИЧНЫХ АРХИТЕКТУР НЕЙРОННЫХ СЕТЕЙ ДЛЯ ВОССТАНОВЛЕНИЯ ПОВЕРХНОСТИ ГОРИЗОНТОВ В МЕЖПРОФИЛЬНОМ ПРОСТРАНСТВЕ НА МОДЕЛЬНОМ ПРИМЕРЕ

Для оценки возможности построения границ контрастных слоев по плотностным и магнитным свойствам алгоритмом на основе нейронных сетей рассмотрим в качестве примера двухслойную модель. На рисунке 1 представлен рельеф границы между двумя слоями, нижний из которых обладает избыточной плотностью 0.5 г/см^3 . Размер участка $300 \times 300 \text{ км}$, расстояние между точками расчёта – 300 метров (рис. 1А). Общий объем точек задания поля составляет 1 002 001 точка. В программе GravMagInv3D [4] рассчитан гравитационный эффект такой модели (рис. 1Б).

Рассмотрим различные архитектуры нейронных сетей для поиска оптимальной. Обучающая и тестовая выборка совпадают и составляют полную рассматриваемую модель. Такой подход позволяет оценить с какой точностью возможно восстановить связь между горизонтом и рассчитанным от него гравитационным эффектом. На вход нейронной сети подавались значения гравитационного эффекта в каждой точке, а на выход – соответствующая глубина залегания горизонта в этой же точке.

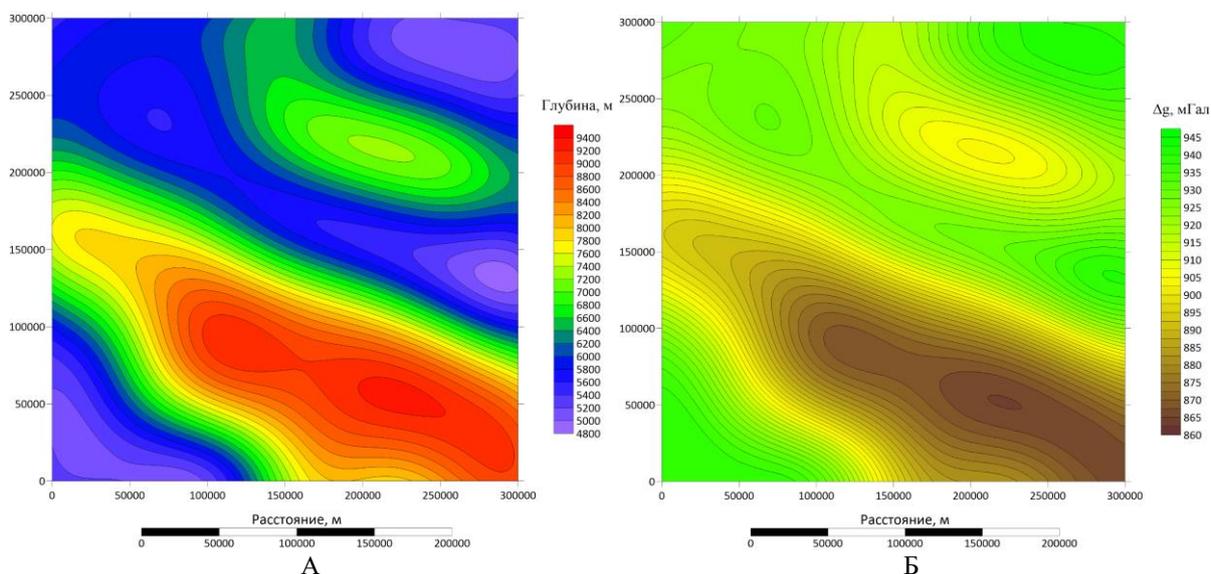


Рис. 1. Модель границы (А) и гравитационный эффект модели (Б)

В качестве примера рассмотрены многослойные нейронные сети прямого распространения. Однако важно отметить, что и иные типы нейронных сетей могут позволить решать поставленную задачу.

В практике машинного обучения для решения конкретно поставленной задачи необходимо выбирать конкретную архитектуру нейронной сети. При этом в литературе не встречается четких подходов или правил по ее выбору. Поэтому для каждого эксперимента сеть выбирается эмпирически.

Для выбора оптимальной архитектуры многослойного персептрона варьировались следующие ее параметры:

- количество слоёв (от 1 до 10);
- количество нейронов в слоях (от 5 до 10 000);
- функции активации для каждого слоя (линейная, сигмоида, гиперболический тангенс, ReLU);
- скорость обучения (от 0.00001 до 1).

Все модели нейронных сетей реализованы на языке Python с использованием библиотеки Tensorflow.

Выбор функции активации во многом зависит от поставленной задачи. В задаче регрессии, которая рассматривается в данной работе, наиболее оптимальными являются линейная функция активации и семейство ReLU (Leaky ReLU, PReLU, RReLU). Одной из проблем стандартного ReLU является нулевой градиент при отрицательных значениях. Чтобы решить эту проблему иногда используется подход ReLU с «утечкой» (Leaky) — график функции активации на отрицательных значениях образует не горизонтальную прямую, а наклонную, с маленьким угловым коэффициентом (порядка 0.01) [5].

Для оценки качества восстановления границы в работе представлены результаты применения нейронных сетей 13 архитектур с различным количеством слоев и нейронов в каждом слое, остальные параметры обучения оставались неизменными: функция активации – ReLU, выходная функция активации – линейная; скорость обучения – 0.0001. Увеличение количества нейронов в слоях не привело к существенному уменьшению ошибки (табл. 1). Так наилучший результат получен при 100 нейронах – 105 м, что составляет около 2% от диапазона изменения горизонта. При этом увеличение числа нейронов приводит к ухудшению сходимости полученного результата с моделью. Последовательное увеличение количества слоёв также не привело к существенному улучшению результатов.

Таблица 1. Оценка параметров среднеквадратического отклонения для различных архитектур нейронных сетей

Тип нейронной сети	СКО, м	Дисперсия, %
1 слой - 5 нейронов	217	4.5
1 слой - 10 нейронов	136	2.8
1 слой - 100 нейронов	105	2.2
1 слой - 1000 нейронов	128	2.7
2 слоя - 10 нейронов	138	2.8
2 слоя - 15 нейронов	107	2.2
2 слоя - 20 нейронов	116	2.4
2 слоя - 100 нейронов	117	2.4
3 слоя - 10 нейронов	139	2.9
5 слоев - 10 нейронов	205	4.3
5 слоев - 100 нейронов	125	2.6
10 слоев - 100 нейронов	124	2.6
10 слоев - 16-32-64-128- 256-256-128-64-32-16 нейронов	104	2.2

После анализа получившихся данных выбрано три архитектуры нейронных сетей, показавшие наилучшие результаты: однослойная со 100 нейронами в слое, двухслойная с 15 нейронами в обоих слоях и десятислойная с количеством нейронов равным двойке в различных степенях. Данные сети выбраны исходя из минимального среднеквадратического отклонения – в них оно составило чуть более 100 метров, что составляет порядка 2% от диапазона изменения горизонта. На рисунке 2 представлены

невязки между исходной границей и полученной по результатам применения трех выбранных нейронных сетей.

Наилучшая точность получена с использованием нейронной сети с последовательным увеличением нейронов от 16 до 256 нейронов к 5 слою, а потом уменьшением нейронов до 16 (табл. 1). По результатам можно сделать вывод, что для поиска такой, достаточно простой зависимости между входными и выходными данными возможно использовать простые архитектуры сетей (однослойные, двухслойные) с небольшим количеством нейронов.

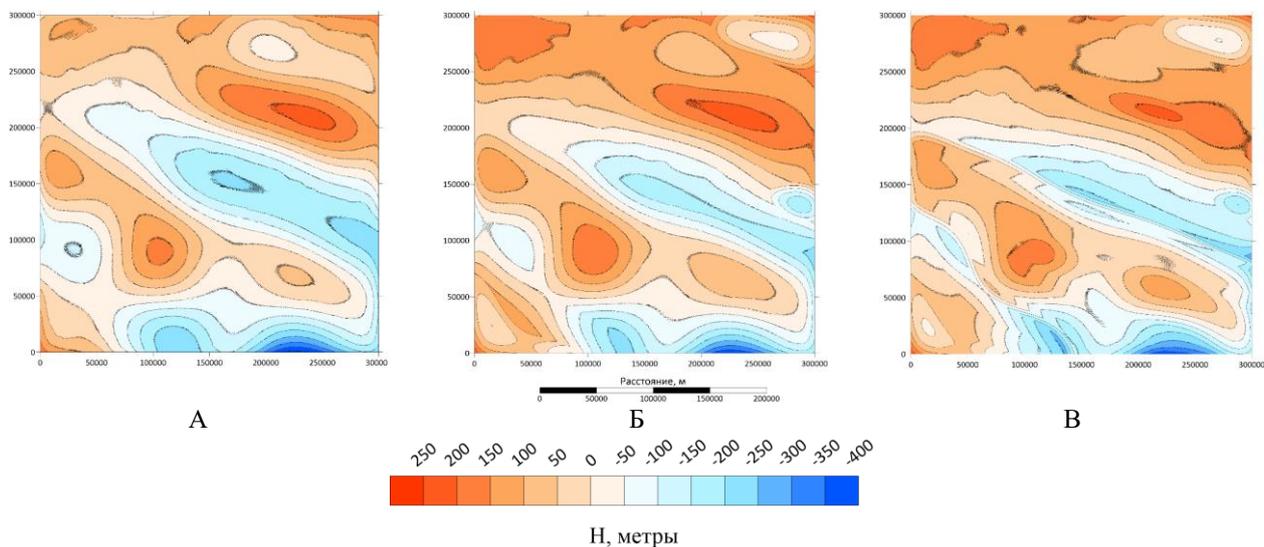


Рис. 2. Разница между исходной моделью границы и результатов применения нейронных сетей:

А – для однослойной нейронной сети со 100 нейронами;

Б – для двухслойной нейронной сети с 15 нейронами в каждом слое;

В – для десятислойной нейронной сети

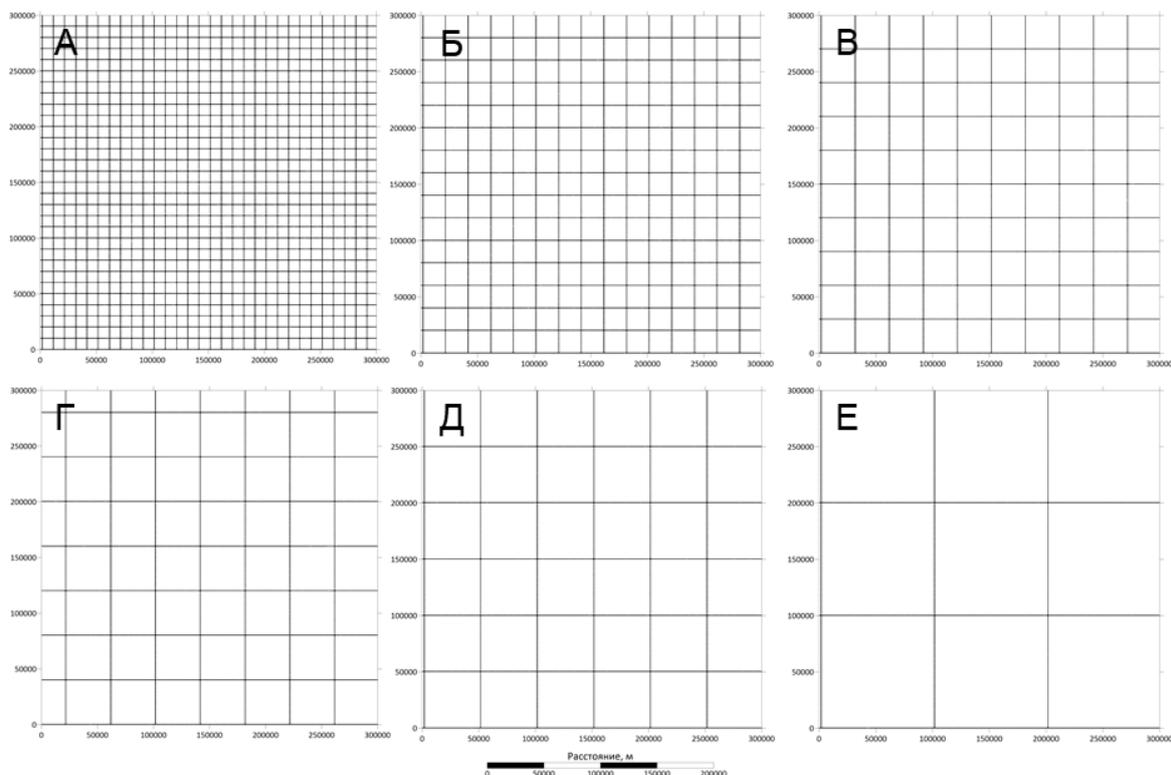


Рис. 3. Схемы профилей, по которым сформированы массивы обучения нейронных сетей с расстоянием между профилями:

А – 10 км, Б – 20 км, В – 30 км, Г – 40 км, Д – 50 км, Е – 100 км

Для оценки возможности применения нейронных сетей для восстановления контрастных по свойствам поверхностей в межпрофильном пространстве составлено 6 различных моделей исходной границы, разреженных по профилям с различным расстоянием между ними (рис. 3): 10 км, 20 км, 30 км, 40 км, 50 км, 100 км. Количество точек для обучения и процентное соотношение от общего количества точек исходной модели представлено в таблице 2.

Таблица 2. Количество точек и процентное соотношение от общего числа для различных сеток

Расстояние между профилями, км	0.3	10	20	30	40	50	100
Количество точек для обучения	1 002 001	172 964	89 008	60 122	44 535	36 684	18 924
Процент от общего числа точек	100%	17.3%	8.9%	6%	4.4%	3.7%	1.9%

Обучение нейронных сетей (однослойной с 100 нейронами, двухслойной с 15 нейронами в каждом слое и нейронной сети с последовательным увеличением нейронов от 16 до 256 нейронов к 5 слою, а потом уменьшению нейронов до 16) проводилось по выборке, полученной из массивов данных вдоль профилей с различным межпрофильным расстоянием. Оценка точности восстановления границы приведена в таблице 3.

Таблица 3. Оценка точности восстановления границы нейронными сетями 3 различных архитектур

Тип нейронной сети	Расстояние между профилями, км					
	10	20	30	40	50	100
	СКО, м					
1 слой - 100 нейронов	105	107	106	105	105	129
2 слоя - 15 нейронов	110	111	106	110	141	131
10 слоев - 16-32-64-128-256-256-128-64-32-16 нейронов	104	105	104	109	108	111

Проанализировав полученные результаты, можно сделать вывод, что для данной задачи, имея значения глубины до горизонта по профилям, покрывающим лишь 5% площади, возможно восстановить структуру отражающего горизонта на всю площадь. Важно отметить, что профили в данном примере расположены равномерно. При расстоянии между линиями 50 и более километров точность ухудшается в 1.3-1.5 раза. Для сопоставления результатов, полученных с применением нейронных сетей различной конфигурации, по выборке заданной по сети 100×100 км проведен секущий диагональный профиль (рис. 4). Сопоставляя графики между собой можно отметить, что максимальные расхождения на графиках наблюдаются в областях локальных экстремумов и на краях области задания, что может быть связано с краевыми эффектами при расчете гравитационного поля модели.

Реконструкция структуры отражающего горизонта возможна и путём решения обратной задачи методом автоматизированного подбора. Для сравнения такой подход применен к рассматриваемой модели в программе GravMagInv3D [4]. Для более корректного решения задачи, в качестве априорной информации была задана истинная избыточная плотность, а в качестве стартовой модели использовался горизонтальный слой с глубиной равной среднему значению глубины структурного горизонта. Результат приведен на рисунке 5. Параметр СКО составил ±50 метров, что в два раза лучше, чем результат работы нейронной сети. Однако стоит отметить, что для корректного решения обратной задачи необходимо строить априорную модель с точным положением границы по глубине. Необходимо подчеркнуть, что оба подхода потребовали одинакового количества расчетного времени.

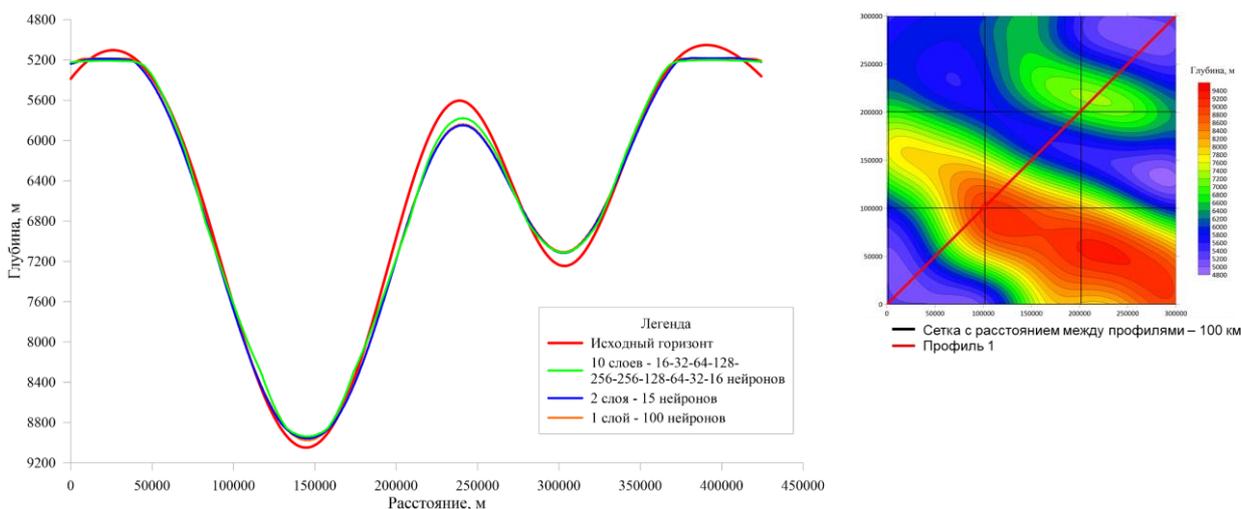


Рис. 4. Сравнение отражающих горизонтов, полученных различными конфигурациями нейронных сетей по выборке заданной по сети 100×100 км по профилю 1.

На врезке представлена исходная модель границы

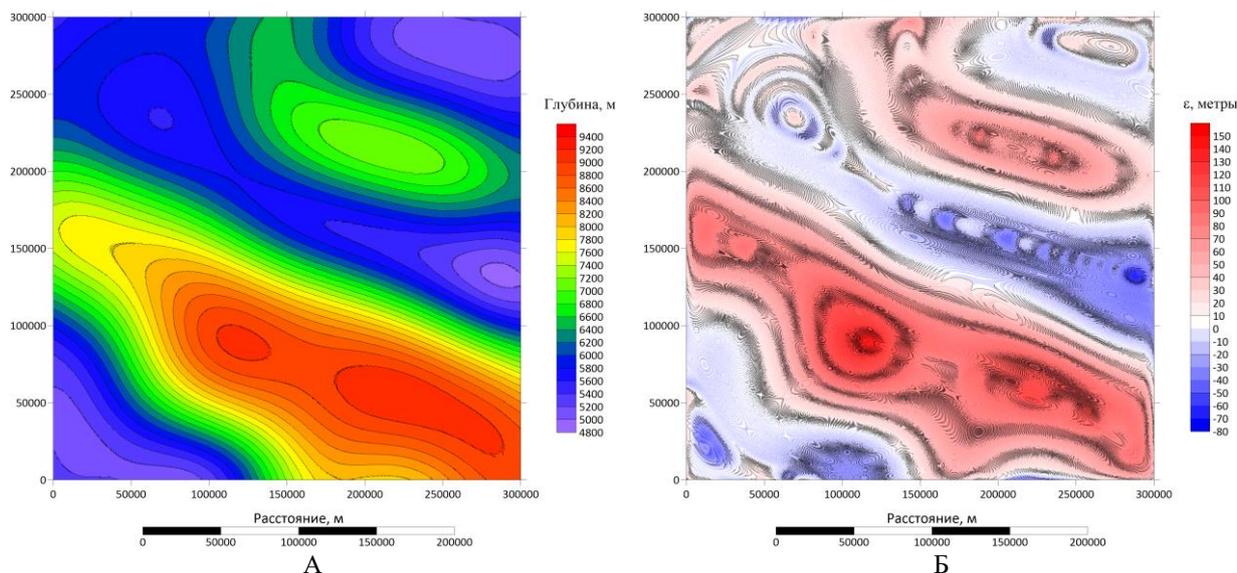


Рис. 5. Результат автоматического решения обратной задачи в программе GravMagInv3D: восстановленный горизонт (А) и расхождение с исходной моделью (Б)

В качестве продолжения эксперимента к гравитационному полю, использованному для обучения нейронной сети, добавлен случайный шум разной дисперсии: 10%, 15%, 20%, 30%, 40% и 50% от амплитуды гравитационного поля. Отражающий горизонт остался без изменения. В качестве обучающего массива использовался отражающий горизонт, разреженный по сети через 30 километров. Результат работы нейронных сетей приведён в таблице 4.

Результаты для трёх нейронных сетей схожи по значениям СКО и по полученным формам горизонтов. Точность восстановления отражающего горизонта при шуме 50% от амплитуды гравитационного поля увеличилась почти в 3 раза. Результат работы 10-слойной нейронной сети для шума 50% представлен на рисунке 6. Высокочастотная составляющая горизонта, полученного с помощью нейронной сети (рис. 6Г) в точности повторяет шум, наложенный на гравитационный эффект (рис. 6Б). На рисунке 7 представлена зависимость между глубиной горизонта и значением гравитационного поля над ним для исходных данных без добавления шума и с ним.

Таблица 4. Результат работы нейронных сетей для разного зашумления данных

Тип нейронной сети	Количество шума					
	10%	15%	20%	30%	40%	50%
	СКО, м					
1 слой - 100 нейронов	121	150	172	199	260	286
2 слоя - 15 нейронов	118	145	166	189	256	274
10 слоев - 16-32-64-128-256-256-128-64-32-16 нейронов	118	143	162	177	243	268

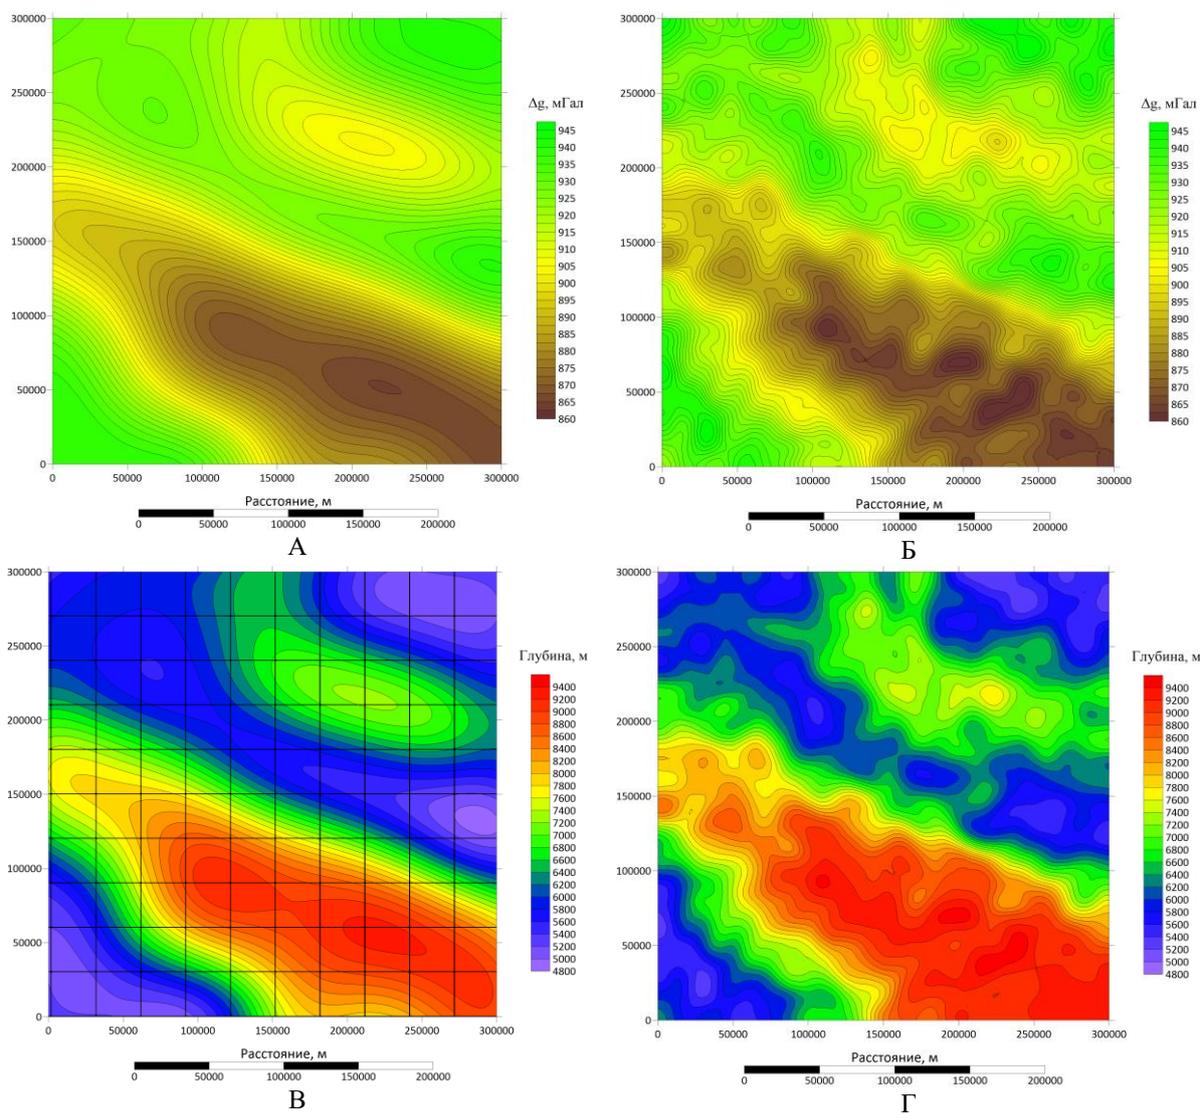


Рис. 6. Результат восстановления горизонта по данным с наложенным шумом (50%) с использованием 10-слойной нейронной сети:

A – гравитационный эффект от отражающего горизонта; Б – гравитационный эффект с наложенным шумом; В – исходный отражающий горизонт с нанесённой сетью профилей 30×30 км; Г – восстановленный отражающий горизонт

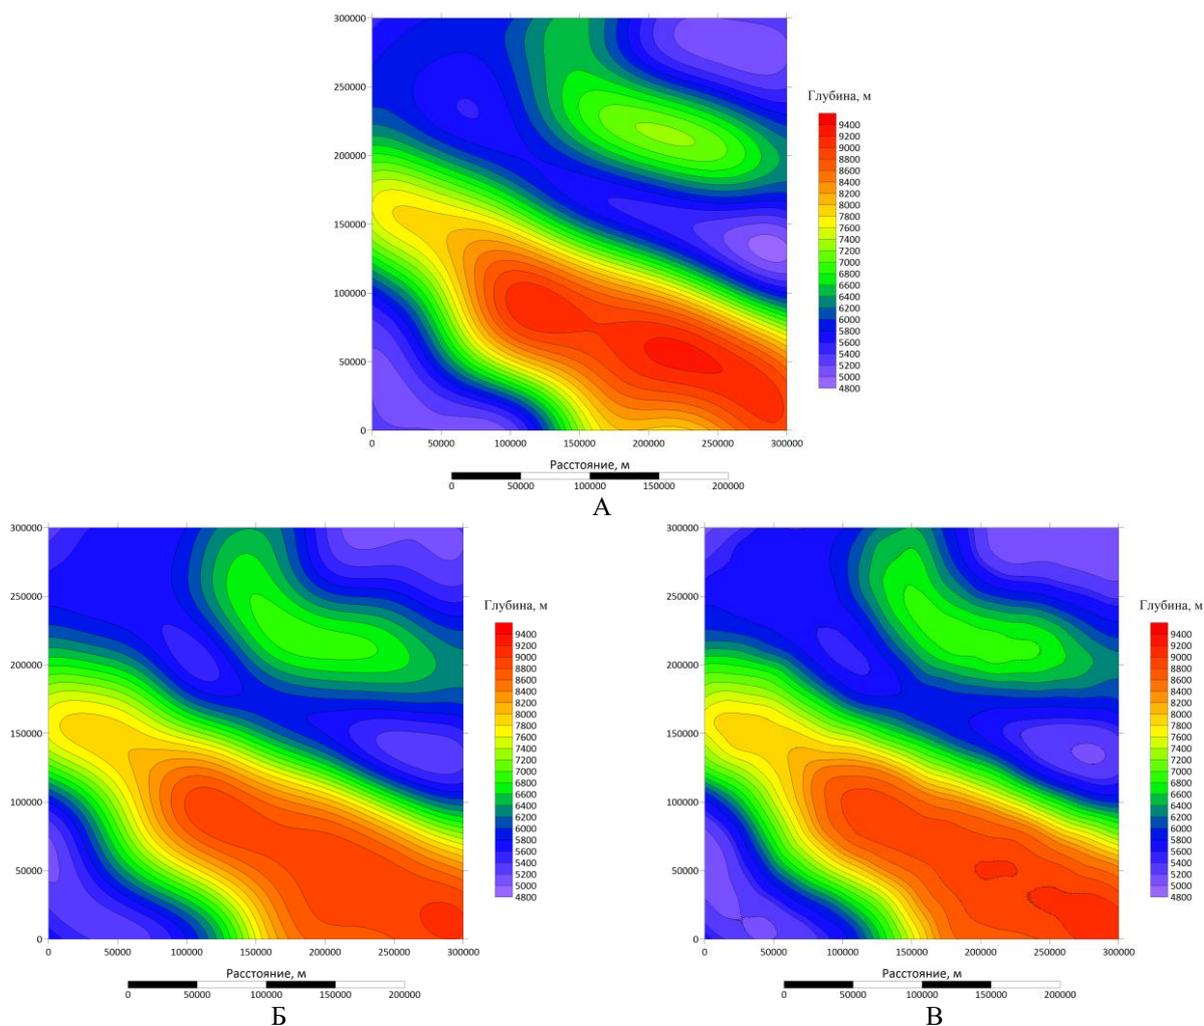


Рис. 7. Сравнение различных результатов восстановления горизонта:
A – исходный горизонт; *Б* – горизонт, полученные после сглаживания; *В* – горизонт, полученный с помощью нейронной сети с добавленными трансформантами

Для улучшения качества восстановления границы возможно в обучающую выборку включить трансформанты потенциальных полей (результаты высокочастотной и низкочастотной фильтрации, пересчёты в верхнее полупространство, производные и др.). При этом выбор трансформант предпочтительнее делать на основе экспертной оценки интерпретатора.

Иным подходом может быть применение фильтрации, сглаживания полученного результата с опорой на сравнение его с гравитационным эффектом.

Для увеличения качества восстановления поля в исходные данные для обучения добавлены четыре трансформанты (низкочастотные фильтры Баттерворта с периодами среза: 70, 80, 90 и 100 км). Результат работы десятислойной нейронной сети представлен на рисунке 7В. Параметр СКО для десятислойной нейронной сети составил 167 метров. Помимо этого, выполнена низкочастотная фильтрация итогового горизонта, полученного в предыдущем эксперименте, фильтром Баттерворта с периодом среза 80 км (рис 7Б). СКО составило 176 метров. Использование в обучающей выборке трансформаций исходного зашумленного поля улучшило результат почти в два раза (с 268 до 167 метров).

Для улучшения качества восстановления границы возможно в обучающую выборку включить трансформанты потенциальных полей (результаты высокочастотной и низкочастотной фильтрации, пересчёты в верхнее полупространство, производные и др.). При этом выбор трансформант предпочтительнее делать на основе экспертной оценки интерпретатора.

Иным подходом может быть применение фильтрации, сглаживания полученного результата с опорой на сравнение его с гравитационным эффектом.

Для увеличения качества восстановления поля в исходные данные для обучения добавлены четыре трансформанты (низкочастотные фильтры Баттерворта с периодами среза: 70, 80, 90 и 100 км). Результат работы десятислойной нейронной сети представлен на рисунке 7В. Параметр СКО для десятислойной нейронной сети составил 167 метров. Помимо этого, выполнена низкочастотная фильтрация итогового горизонта, полученного в предыдущем эксперименте, фильтром Баттерворта с периодом среза 80 км (рис 7Б). СКО составило 176 метров. Использование в обучающей выборки трансформаций исходного зашумленного поля улучшило результат почти в два раза (с 268 до 167 метров).

3. ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В КАЧЕСТВЕ АЛГОРИТМА ДЛЯ ВОССТАНОВЛЕНИЯ НЕСКОЛЬКИХ ПЛОТНОСТНЫХ ГРАНИЦ НА РЕАЛЬНЫХ ДАННЫХ

Нейронные сети могут описывать не только однопараметрические зависимости, а также могут быть применимы к описанию зависимости между векторами. В частности, можно построить алгоритм восстановления не одной структурной поверхности, а сразу нескольких.

Рассмотрим в качестве примера задачу построения трех отражающих горизонтов (горизонты «1», «2» и «3») на площади с известным распределением аномальных гравитационного и магнитного полей (рис. 8А, Д). В качестве обучающей выборки используются данные, полученные в результате интерпретации материалов сейсморазведки (рис. 8Б-Г). Средняя глубина для горизонта «1» составляет 850 метров, для «2» – 1730 метров, для «3» – 2180 метров, а перепады глубин составляют от 350 до 1180 метров для горизонта «1», от 670 до 2290 метров для «2», от 670 до 3040 метров для «3» соответственно. Наряду с самими потенциальными полями использованы их трансформанты:

- Гравитационное поле: высокочастотный фильтр Баттерворта 10, 15 и 20 км, низкочастотные фильтры Баттерворта 10, 20, 30 км, пересчет в верхнее полупространство на 10 км;
- Магнитное поле: низкочастотный фильтр Баттерворта 5 км.

Для построения регрессионных зависимостей и обучения нейронных сетей использовано 54 627 точек, для восстановления – 91 343 точек, расстояние между точками – 250 м.

В ходе работ рассмотрено несколько конфигураций нейронных сетей. Результат с наименьшей невязкой обеспечивает двухслойная нейронная сеть с 30 и 3 нейронами в первом и втором слоях соответственно. В качестве входного сигнала для нейронной сети рассмотрены 12 полей (гравитационное и магнитное поля и их трансформанты) и 3 отражающих горизонта, находящихся на различных глубинах. Результаты работы нейронной сети представлены на рисунке 8Е-З.

Для оценки качества восстановления горизонтов, рассчитаны разностные поля (разность между картами рельефа отражающих горизонтов и восстановленными полями с помощью нейронной сети) (рис. 9). Среднеквадратическое отклонение составило ± 20 метров. Области максимального расхождения горизонтов находятся в областях его максимального градиента.

4. ВЫВОДЫ

На сегодняшний день применение алгоритмов на основе нейронных сетей позволяет решать широкий круг задач геофизики. Однако, их применение в обработки и интерпретации геопотенциальных полей встречается редко.

В ходе работы построен и протестирован на модельных и реальных данных алгоритм на основе многослойных нейронных сетей прямого распространения для решения задачи восстановления структурных границ по потенциальным полям с опорой на данные с уже известным положением искомой границы. Рассмотренный алгоритм на основе нейронных сетей может быть использован для построения структурных горизонтов с опорой на имеющиеся сети профильных данных, так и с опорой на площадные данные. Этот подход может найти свое место при построении объемных геолого-геофизических моделей.

Описанные в работе подходы на основе нейронных сетей могут стать одним из инструментов для интерпретации потенциальных полей. На их основе возможно доработать и создать новые подходы для решения различных задач гравиразведки и магниторазведки.

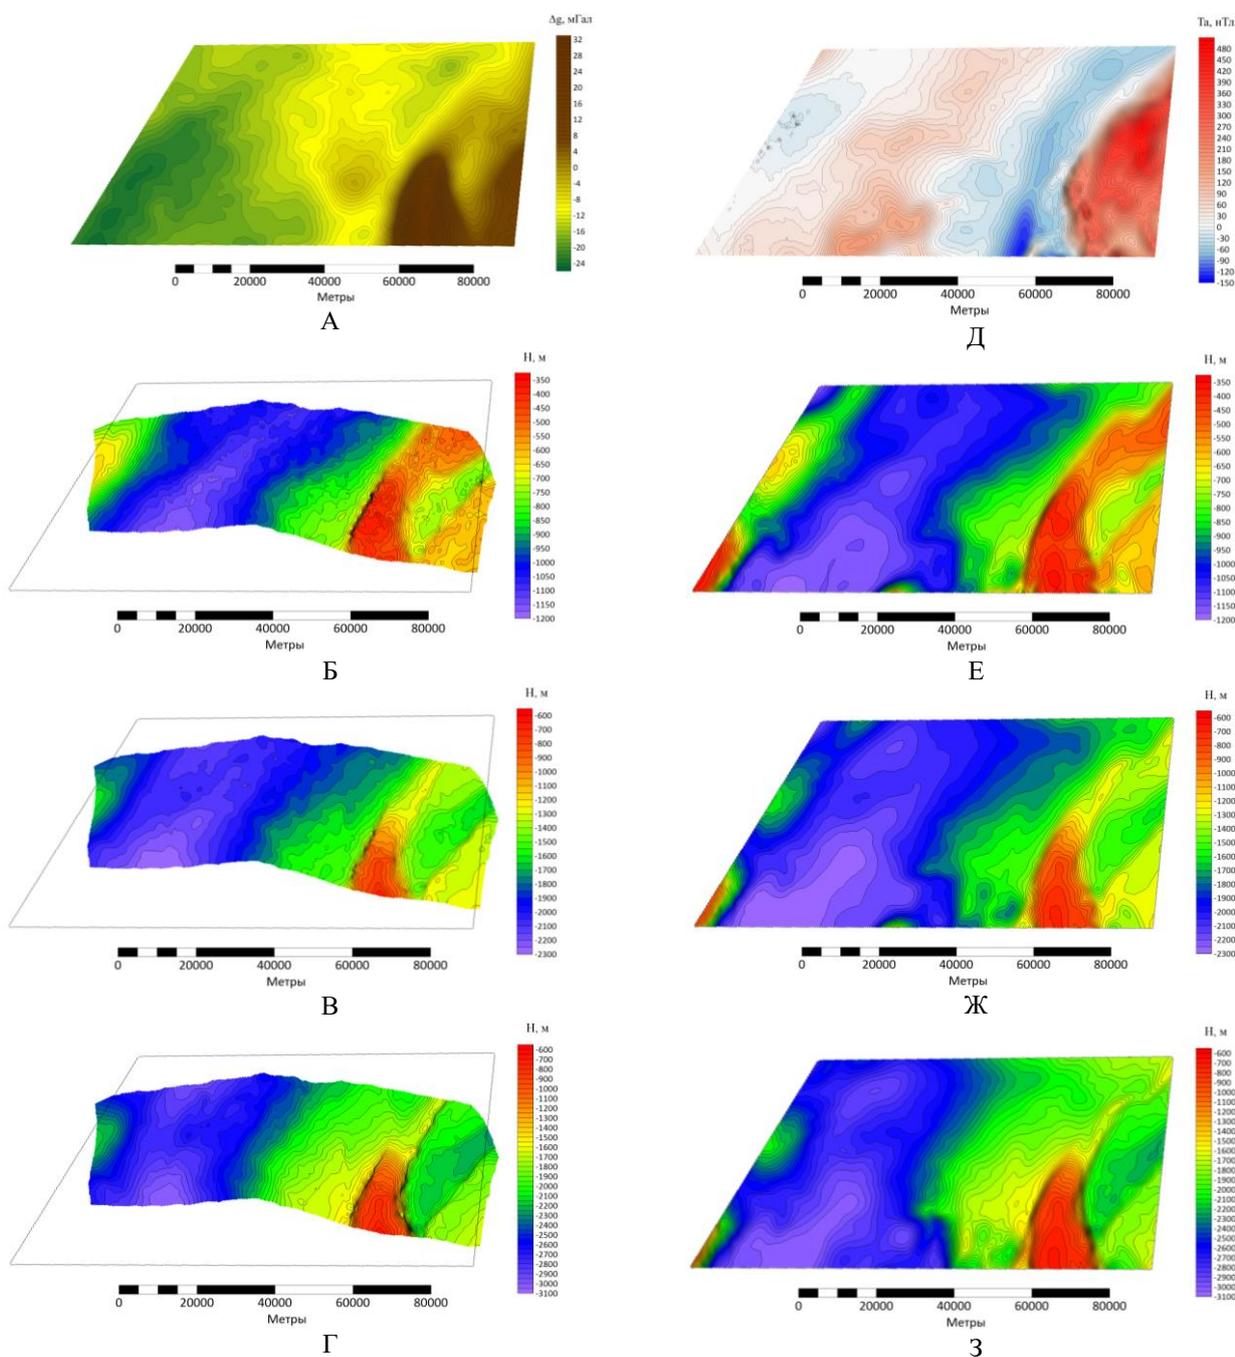


Рис. 8. Результаты восстановления отражающих горизонтов с помощью нейронной сети
 Исходные данные: А – магнитное поле; Д – гравитационное поле; Б – отражающий горизонт «1»; В –
 отражающий горизонт «2»; Г – отражающий горизонт «3». Восстановленные отражающие горизонты Е –
 «1»; Ж – «2»; З – «3»

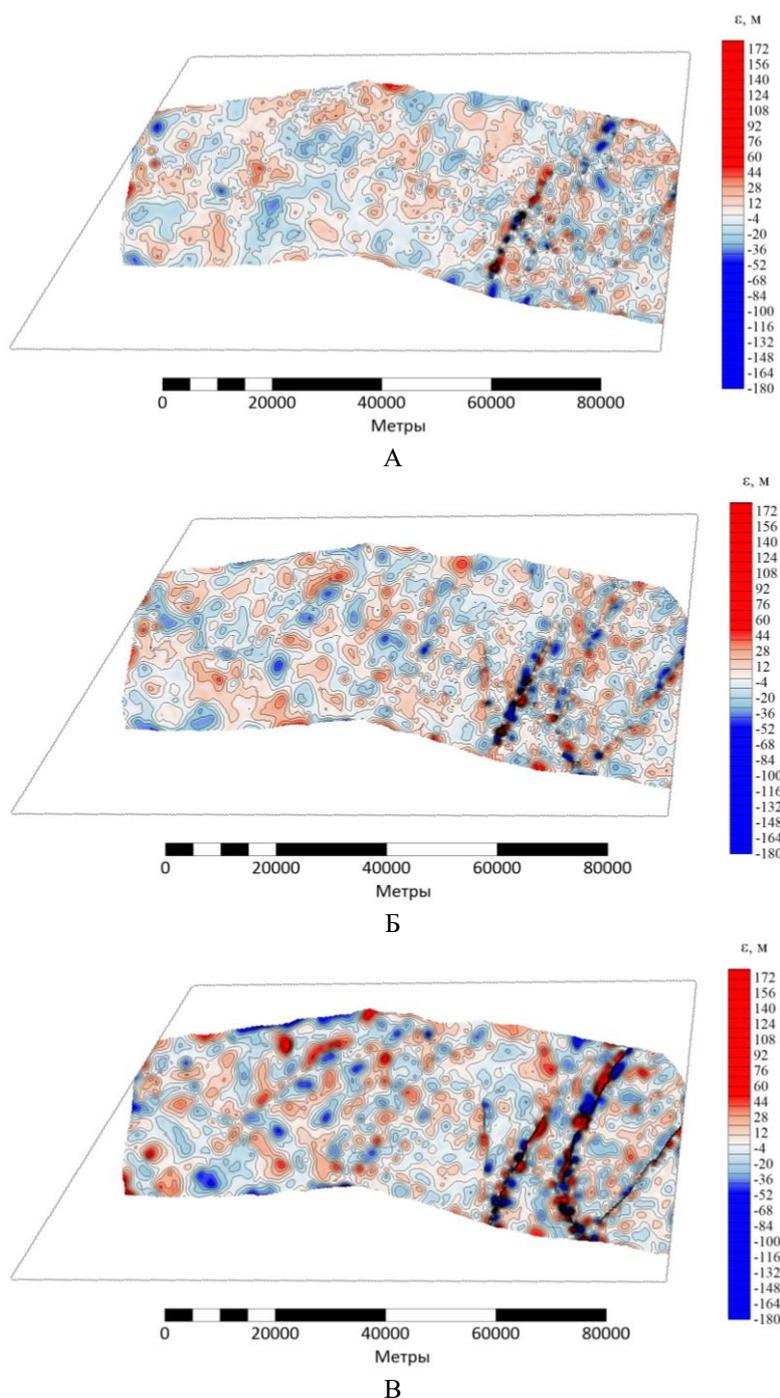


Рис. 9. Расхождения результатов, полученных с использованием нейронной сети и исходных горизонтов:
А – отражающий горизонт «1»; Б – отражающий горизонт «2»; В – отражающий горизонт «3»

Важно отметить, что несмотря на активное развитие реализации нейронных сетей на персональных компьютерах, зачастую их применение требует использование более мощных систем вплоть до суперкомпьютеров. Также важным является то, что подбор архитектуры, параметров нейронных сетей выполняется эмпирическим путем, что требует большого временного ресурса.

Несмотря на вышеописанное, активное развитие технологий применения нейронных сетей делает это направление перспективным. Стоит отметить, что поскольку нейронные сети помогают найти сложные функциональные связи между параметрами поля и атрибутами изучаемой среды, то они могут быть эффективны, особенно при решении задач комплексной интерпретации геолого-геофизических данных.

Методика построения структурных поверхностей с применением алгоритмов машинного обучения, описанной в данной статье, может лечь в основу алгоритмов моделирования солнечно-земных связей.

ЛИТЕРАТУРА

1. *Никитин А.А., Петров А.В.* Теоретические основы обработки геофизической информации. Учебное пособие – Москва, Издательство 2008. 112 с.
2. *Гулин В.Д., Ананьев В.В., Григорьев Г.С., Зайцев С.В. и др.* Применение алгоритмов машинного обучения для восстановления структурного каркаса по данным потенциальных полей в зонах отсутствия данных сейсморазведки. Материалы 48-й сессии Международного научного семинара им. Д. Г. Успенского – В. Н. Страхова, 2022. С. 90-94.
3. *Колмаков А.В., Трусов А.А., Мейснер А.Л., Григорьев Г.С.* Моделирование морфологии отражающих горизонтов в межпрофильном пространстве по данным потенциальных полей методами глубокого обучения. ГеоЕвразия-2020. Современные технологии изучения и освоения недр Евразии Том III, 2021. С. 76-80.
4. Свидетельство 2022610137. GravMagInv Программное обеспечения для комплексной интерпретации данных гравиразведки и магниторазведки. программа для ЭВМ / *Чениго Л.С.* (RU); опубли. 10.01.2022.
5. *Andrew L. Maas, Awni Y. Hannun, Andrew Y. Ng.* Rectifier nonlinearities improve neural network acoustic models // Proc. ICML. — 2013. — Июнь (т. 30, вып. 1).

APPLICATION OF MACHINE LEARNING TO RECOVER STRUCTURAL BOUNDARIES FROM POTENTIAL FIELDS

Shklyaruk A. D., Kuznetsov K. M.

The paper considers approaches to the reconstruction of layer boundaries of contrasting density and magnetic properties based on machine learning. The paper demonstrates algorithms based on multilayer neural networks of direct propagation for solving the problem of structural boundaries reconstruction by potential fields. To train them, we propose to use either profiles or regions with already known position of the desired boundary. The approach is based on the construction of regression relationships between gravitational and magnetic fields, as well as their transformants and reflecting horizons, determined, for example, by the results of seismic data interpretation.

KEYWORDS: MACHINE LEARNING, NEURAL NETWORKS, STRUCTURAL HORIZONS, COMBINING GEOPHYSICAL METHODS, GRAVITY SURVEY, MAGNETIC SURVEY, GEOLOGICAL AND GEOPHYSICAL MODELS