

# ИЕРАРХИЧЕСКИЕ НЕЙРОННЫЕ СЕТИ В ЗАДАЧАХ ПРОГНОЗА СВОЙСТВ КОЛЛЕКТОРОВ НЕФТИ И ГАЗА ПО СКВАЖИННЫМ И СЕЙСМИЧЕСКИМ ДАННЫМ

И.И. Приезжев<sup>1,2</sup>, Д.А. Данько<sup>1</sup>, , А.Н. Онищенко<sup>2</sup>

<sup>1</sup> Российский государственный научно-исследовательский университет нефти и газа им. И.М. Губкина, 119991, Москва, Ленинский просп., 65, Россия

<sup>2</sup> ООО «Лаборатория Приезжева», 119234, Москва, Ленинские горы, 1, Россия

Поступила в редакцию: 27.05.2024

Принята в печать: 02.08.2024

Опубликована онлайн: 05.08.2024

DOI: [10.15372/GiG2024141](https://doi.org/10.15372/GiG2024141)

EDN: [QHBLVO](https://www.edn.ru/QHBLVO)

Ссылка для цитирования:

Приезжев И.И., Данько Д.А., Онищенко А.Н. (2025). Иерархические нейронные сети в задачах прогноза свойств коллекторов нефти и газа по скважинным и сейсмическим данным // Геология и геофизика, т. 66, № 1, с. 131–140, DOI: [10.15372/GiG2024141](https://doi.org/10.15372/GiG2024141), EDN: [QHBLVO](https://www.edn.ru/QHBLVO).

© И.И. Приезжев, Д.А. Данько, А.Н. Онищенко

 E-mail: [danko.d@gubkin.ru](mailto:danko.d@gubkin.ru)

Представлен метод иерархических нейронных сетей, основанный на методе «ближайшего соседа» с предварительной кластеризацией исходного обучающего массива и построением поискового кластерного дерева решений, который является серьезной альтернативой нейросетевым технологиям с глубоким обучением и имеет ряд преимуществ: в скорости обучения, идентификации объектов с низкой степенью подобия, способности к генерализации и дообучению. Его опробование на реальных данных Западно-Сибирской нефтегазоносной провинции показало эффективность и быстроту прогноза нефтенасыщения в интервале викуловской свиты по сравнению с инверсионными подходами количественной интерпретации данных сейсморазведки при достаточно схожих геологических результатах. Это характеризует предложенный метод иерархических нейронных сетей как эффективный инструмент количественной интерпретации данных сейсморазведки для решения геологических задач.

*Нейронные сети, сейсморазведка, интерпретация, викуловская свита, нефть и газ, Западная Сибирь*

## ВВЕДЕНИЕ

Применение методов машинного обучения в различных областях науки в последние годы показало ошеломляющие результаты. Благодаря использованию огромного объема информации стали возможны классификация, распознавание и генерация речи и текстов, появились умные чат-боты, виртуальные помощники и многое другое. Относительная универсальность алгоритмов и схожесть задач позволяют использовать методы машинного обучения в смежных областях исследований, в том числе в интерпретации скважинных и сейсмических данных для целей прогноза перспективных нефтегазоносных объектов.

Для решения таких задач широко распространенными являются методы машинного обучения, в которых прогноз основан на использовании обучающего массива данных, состоящего из набора пар ( $X$ ,  $Y$ ), где  $X$  – вектор значений, характеризующий свойства или характеристику объектов (вектор признаков объектов);  $Y$  – вектор значений прогнозного параметра.

Наиболее распространенным способом получения прогноза по анализируемому набору данных является применение алгоритмов глубокого машинного обучения, основанных на использовании многослойных нейронных сетей. При постановке задачи прямого прогноза коллекторских свойств по скважинным данным и сейсморазведки обучающий массив может

быть огромным. Подобное часто встречается, когда в проекте участвует большое количество скважин, а данные сейсморазведки представлены на значительных площадях или имеют высокую кратность. В этом случае для прогноза коллекторских свойств требуется большая многослойная нейронная сеть, которую будет очень сложно обучить, а сам процесс обучения будет занимать достаточно продолжительное время, что не всегда возможно в условиях сжатых сроков выполнения проекта. Кроме того, нейронные сети очень чувствительны к качеству сейсмостратиграфической привязки скважинных и сейсмических данных, если прогноз выполняется во временной области, а также к качеству обработки самих сейсмических волновых полей. Это приводит к получению зашумленных и латерально прерывистых результатов прогноза и снижению восстановления прогнозных параметров в местах положения скважин.

Другим не менее распространенным подходом является метод «ближайших соседей», который представляется очень простым и популярным алгоритмом в различных областях применения машинного обучения. Он заключается в прямом сравнении всех признаков анализируемого объекта с признаками объектов из обучающего множества. В этом методе отсутствует этап обучения, а результат прогноза вычисляется на основе выбора наиболее похожих элементов пар обучающего массива. Из-за высокой сте-

пени свободы и гладкости поля «близости» метод «ближайших соседей» менее чувствителен к качеству сейсмостратиграфической привязки и к зонам понижения качества сейсмического волнового поля. Один из главных недостатков этого метода – необходимость выполнения операции сравнения изучаемых объектов с каждым элементом обучающего массива. Если этот массив имеет большие размеры, то применение данного метода может занимать недопустимо длительный период времени.

Для ускорения поиска «ближайшего соседа» существует множество подходов, например, метод построения графа для иерархического поиска [Malkov, Yashunin, 2018]. Нами предлагается применение подобного метода, относящегося к иерархическим нейронным сетям, в котором используется последовательная кластеризация исходного обучающего массива и построение поискового кластерного дерева решений.

## МЕТОД ИЕРАРХИЧЕСКИХ НЕЙРОННЫХ СЕТЕЙ

В основе предлагаемого подхода лежит идея ускорения метода «ближайших соседей» путем предварительного создания поискового кластерного дерева решений по обучающей выборке.

В задачах прогноза свойств коллекторов нефти и газа по данным скважинных измерений и сейсморазведки предлагаемый метод может быть представлен в виде схемы, состоящей из следующих блоков (рис. 1).

**Блок 0. Подготовка входных данных.** Данный блок не относится напрямую к рассматриваемой методике, однако является обязательным для всех видов научно-производственных работ, связанных с количественной интерпретацией данных сейсморазведки. В него включены этапы сбора, анализа, загрузки и контроля качества входной геолого-геофизической информации. Особое внимание уделяется подготовке скважинных данных и волновых полей для выполнения количественного прогноза. Сейсмические данные должны быть обработаны с сохранением истинного распределения амплитуд и иметь высокое соотношение сигнал/шум. По скважинным

данным должны быть рассчитаны целевые прогнозные параметры, согласующиеся с данными геофизических исследований скважин (ГИС) и лабораторными измерениями на керне, например, объемные распределения минерального состава пород, фильтрационно-емкостные и геомеханические свойства, флюидонасыщение, дискретные распределения. Особое внимание должно быть уделено взаимной увязке скважинных и сейсмических данных во временном или глубинном масштабе.

**Блок 1. Формирование обучающей выборки.** Обучающая выборка формируется путем группирования входных сейсмических данных и целевых прогнозных параметров в скважинах путем создания набора пар *сейсмический отклик–прогнозный параметр* (в данной работе «отклик» и «параметр», выделенные курсивом, описывают именно пары обучающей выборки). В качестве входных сейсмических сведений могут быть использованы как полнократные суммарные данные, так и частично-кратные суммы или подготовленный набор сейсмограмм после миграции (рис. 2).

В приведенном примере целевым прогнозным параметром является непрерывное распределение пористости, полученное по результату интерпретации данных ГИС. При формировании одной пары обучающего массива *прогнозный параметр* соответствует среднему значению пористости, попадающего в ячейку регулярной сейсмической сетки, и рассчитывается вдоль траектории ствола скважины. *Сейсмический отклик* представляет собой окно сейсмического волнового поля размерами  $m \times n$ , где  $m$  – количество отсчетов по вертикали во временном или глубинном масштабе входных сейсмических данных,  $n$  – количество соседних трасс. При этом центр окна соответствует расположению ячейки прогнозного параметра. Значения  $m$  и  $n$  являются пользовательскими и подбираются в процессе выполнения количественного прогноза.

**Блок 2. Построение поискового кластерного дерева решений.** В основе его построения лежит идея разноразмерной кластеризации сейсмических откликов в зависимости от их схожести или различия меж-

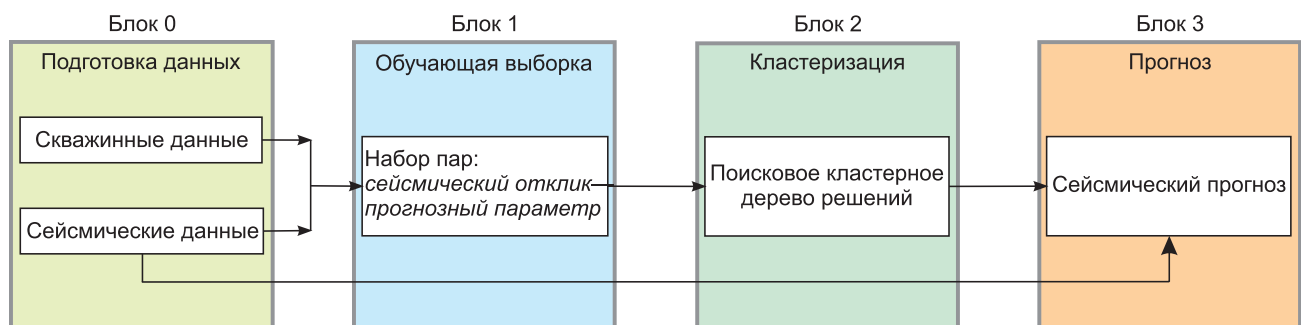
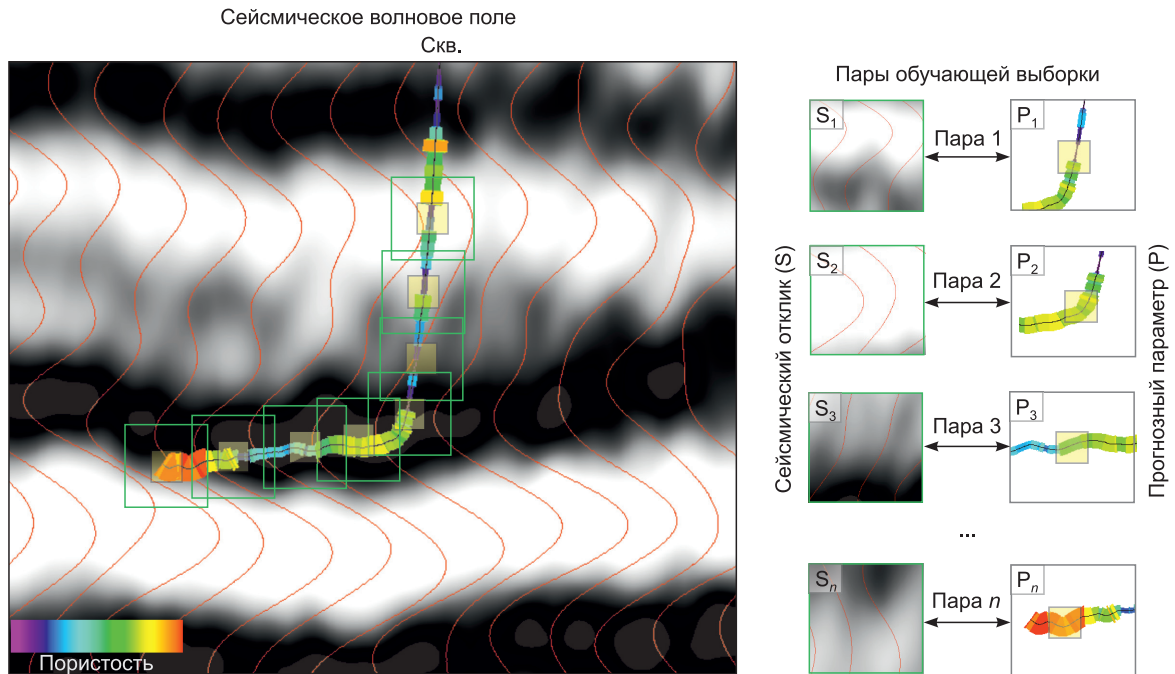


Рис. 1. Схема применяемых иерархических нейронных сетей.



**Рис. 2.** Принцип формирования обучающей выборки с использованием скважинных и сейсмических данных. Здесь и на рис. 4 цветовая шкала пористости показывает изменение значений от низких (холодные тона) к высоким (теплые тона), а пористость выбрана в качестве примера прогнозного геологического параметра. Зеленый квадрат означает окно, в котором определяется сейсмический отклик. Вместе со значением прогнозного параметра (желтое окно) формируются пары обучающей выборки.

ду собой. В результате формируются группы кластеров сейсмических откликов с высокой степенью подобия на конечных узлах дерева («листьях» дерева), которые имеют соответствующие значения целевых прогнозных параметров. Такой подход значительно ускоряет процесс принятия решения или, как в нашем случае, ускорение получения распределений целевых параметров в межскважинном пространстве по данным сейсморазведки с помощью метода «ближайшего соседа» или нескольких «ближайших соседей» по сравнению с простым перебором.

Построение поискового кластерного дерева решений выполняется по набору сейсмических откликов из пар обучающей выборки, сформированных в блоке 1 (см. рис. 2). В начальном («корневом») узле дерева решений входной набор *сейсмических откликов* разделяется на заданное количество кластеров. Далее, в последующем внутреннем узле дерева, каждый кластер верхнего уровня разделяется на кластеры нижнего уровня и таким образом до самого нижнего уровня – «листьев» дерева решений (рис. 3).

Количество кластеров и глубина дерева определяется пользователем в процессе анализа параметров при выполнении количественного прогноза. Если выполнять деление на два кластера для каждого узла, то можно получить бинарное поисковое дерево. Деление на большее число кластеров позволяет строить более сложные поисковые деревья с появлением

«листьев» на различных уровнях. Если задать минимальное количество объектов в «листьях», то глубина дерева определяется автоматически.

Процесс кластеризации выполняется с помощью алгоритма классификации без учителя – самоорганизующейся карты Кохонена [Kohonen, 2012] – с использованием вариантов проекции многомерного пространства Kohonen 1D/2D/3D [Priezzhev et al., 2019]. При таком подходе два сейсмических отклика будут отнесены к одному кластеру, если их формы будут подобны. Мера подобия определяется по расстоянию между формами откликов в многомерном пространстве. При этом каждое измерение пространства соответствует положению отсчета на сейсмическом отклике. В простом случае расстояние можно определить как разность квадратов между двумя откликами ( $L_2$  – норма).

Математически процедура классификации для одного уровня дерева может быть описана следующим образом. Для простоты рассмотрим вариант кластеризации Kohonen 1D. Пусть обучающая выборка блока 1 включает элемент  $S_i$  как  $i$ -й сейсмический отклик, который содержит  $n$  сейсмических отсчетов  $S_i = \{s_{1i}, s_{2i}, \dots, s_{ni}\}$ . Использование алгоритма Kohonen 1D предполагает создание нейронной сети заранее заданного размера  $k$ , где каждый  $j$ -й нейрон ( $j = 1, k$ ) описывается векторами с тем же размером  $W_j = \{w_{1j}, w_{2j}, \dots, w_{nj}\}$ .

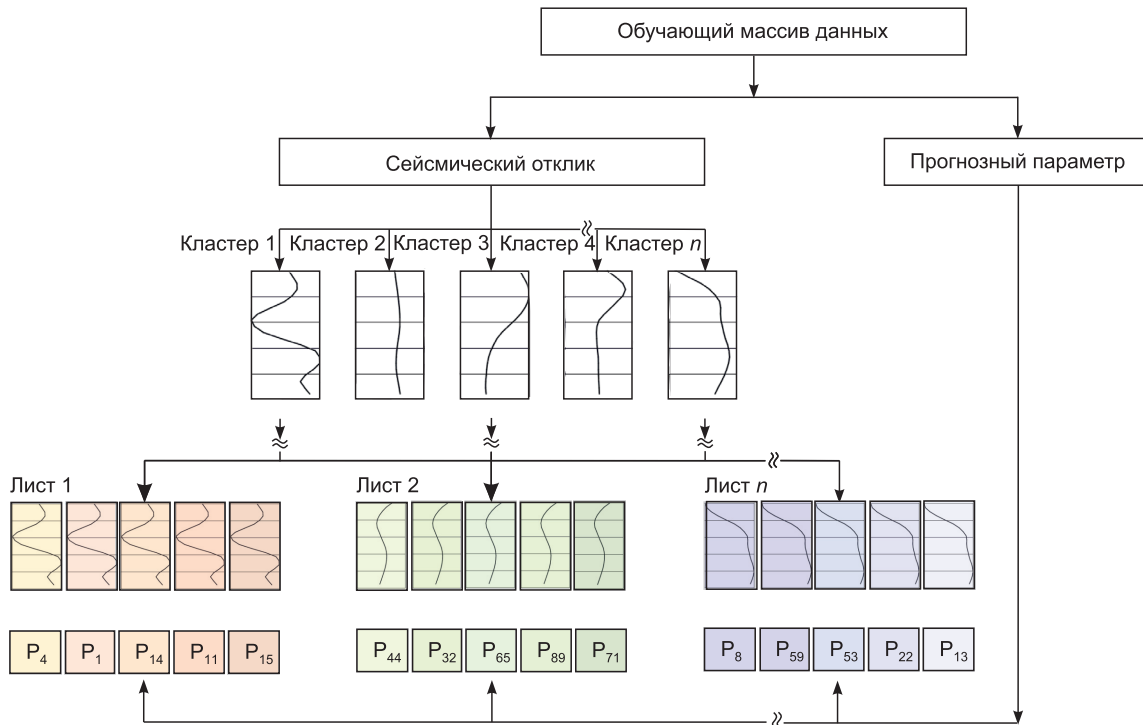


Рис. 3. Схема построения кластерного дерева решений.

Первоначально нейроны инициализируются случайно выбранными сейсмическими откликами из обучающей выборки. Далее организуется цикл по всем элементам сейсмических откликов  $S_i$  из обучающей выборки, и находится ближайший нейрон «победитель»  $W_j$  из нейронной сети с использованием различных мер близости, например, в виде нормы  $L_2$ :

$$L_2(S_i, W_j) = \sqrt{\frac{1}{n} \sum_{l=1}^n (s_{li} - w_{lj})^2}.$$

Затем значения нейрона «победителя» корректируются с весами  $a_{ij}$ , обратно пропорциональными количеству ранее включенных в него сейсмических откликов (выполненных коррекций):

$$W_j^{\text{новый}} = W_j^{\text{старый}} + a_{ij} S_i.$$

Также корректируются значения нейронов, близких по индексу  $j$  к нейрону «победителю». Корректировка осуществляется с помощью весовых коэффициентов, значения которых увеличиваются по мере приближения к нейрону «победителю».

Для варианта кластеризации Kohonen 2D и Kohonen 3D используется структура расположения нейронов с двумя индексами  $j^1, j^2$  и размером  $k \cdot k$  (карта классов) или с тремя индексами  $j^1, j^2, j^3$  размером  $k \cdot k \cdot k$  (куб классов) соответственно. В этом случае корректируются значения нейронов, близкие по всем индексам к нейрону «победителю». Полученные индексы можно интерпретировать как новые переменные, и алгоритм кластеризации Kohonen

1D/2D/3D может рассматриваться не только как метод группирования похожих объектов (сейсмических откликов), но и как метод сокращения признакового пространства размером  $n$  до размера  $k$  (1D),  $k \cdot k$  (2D) или  $k \cdot k \cdot k$  (3D). Повышение размерности кластеризации до 2D или 3D уменьшает возможность получения ошибки кластеризации, что улучшает качество поисковых кластерных деревьев при построении иерархической нейронной сети.

После создания кластерного дерева выполняется анализ пар *сейсмический отклик–прогнозный параметр* в каждом «листе» дерева. Логично предположить, что если сейсмические отклики в каждом «листе» имеют высокую меру подобия, то и *прогнозные параметры* также должны быть подобны друг другу. В этом случае применение метода « $k$ -ближайших соседей» позволяет «усреднять» пары с учетом весовых коэффициентов их меры подобия и/или пространственной близости. В случае прогноза дискретных значений свойств по скважинным данным, таких как «коллектор»/«не коллектор» или литофации, операция «усреднения» выполняется выбором максимального количества одинакового значения в списке ближайших соседей. Это позволяет получить в качестве результата наиболее вероятный прогнозный параметр среди « $k$ -ближайших соседей». Если прогнозные параметры достаточно сильно отличаются друг от друга в пределах одного «листа», то это является индикатором низкой либо отсутствующей связанности *сейсмический отклик–прогнозный параметр* в обучающей выборке.



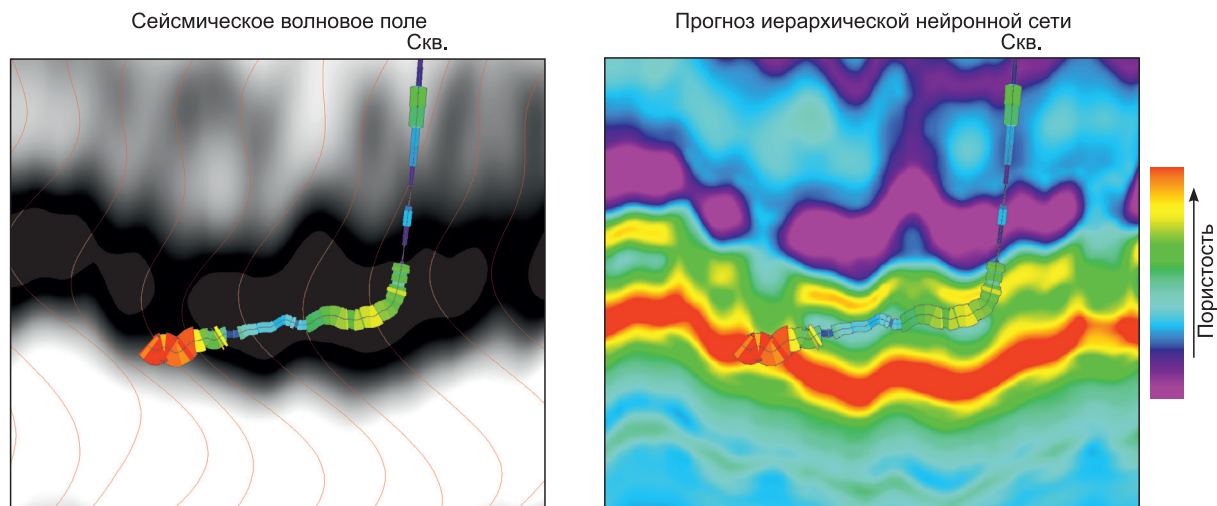


Рис. 4. Пример прогноза пористости иерархической нейронной сети по сейсмическим данным.

### Блок 3. Прогноз по данным сейсморазведки.

В рамках данного блока выполняется прогноз целевых параметров по всему набору сейсмических данных с использованием метода «ближайших соседей» на основе поискового кластерного дерева решения, созданного в предыдущем блоке.

Весь набор сейсмических данных, который использовался при формировании обучающей выборки, подается на вход кластерного дерева решений. В пределах заданного пользователем временного окна (целевого интервала) сейсмический отклик в каждой трассе входного набора сравнивается с *сейсмическими откликами* в каждом кластере поискового дерева решений. Процесс сравнения начинается с корневого узла и заканчивается одним из «листьев» дерева. В результате сейсмическому отклику присваивается значение целевого *прогнозного параметра* в соответствии с парами обучающей выборки (рис. 4).

Если во входных сейсмических данных присутствует отклик, имеющий низкую степень подобия с откликами из обучающей выборки и, соответственно, не использующийся в кластеризации при создании дерева решений, то такой отклик помещается в отдельный неразмеченный кластер. Все последующие отклики, имеющие сходство с откликом из неразмеченного кластера, добавляются в этот кластер. В противном случае создается новый неразмеченный кластер со следующим порядковым номером. Таким образом происходит дообучение, и эти новые кластеры могут быть добавлены в процесс распознавания образов и прогноза целевых параметров по всему набору сейсмических данных.

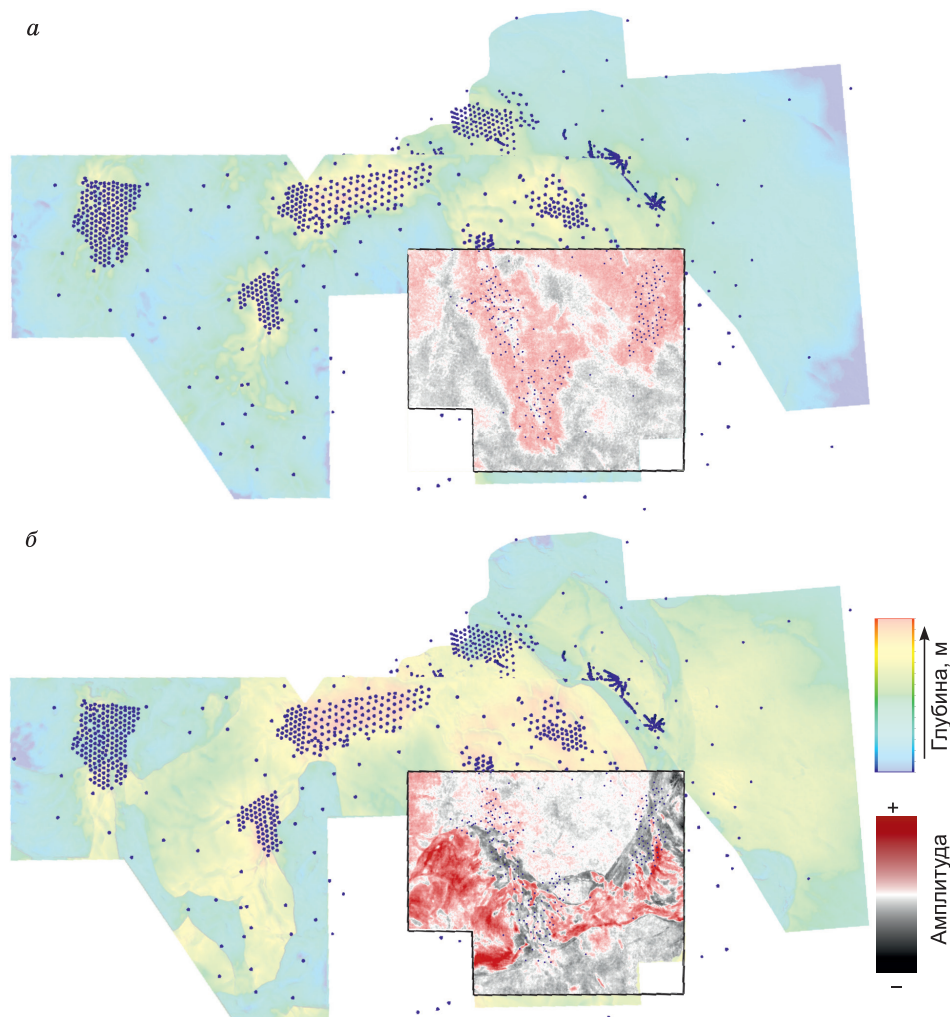
### ОПРОБОВАНИЕ НА РЕАЛЬНЫХ ДАННЫХ

Опробование предложенного алгоритма иерархических нейронных сетей было выполнено на одном

из месторождений Красноленинского свода Западной Сибири. В качестве целевого объекта рассматривались терригенные отложения викуловской свиты верхнеаптских-нижнеальбских отложений нижнего мела. Нефтеносность свиты связана с мелководно- и прибрежно-морскими песчаниками пластов  $BK_1$ ,  $BK_{2-3}$ , имеющими линзовидное строение. Залежи нефти являются недонасыщенными и характеризуются обширными переходными водонефтяными зонами и повышенным водосодержанием пород, что приводит к высокой обводненности при эксплуатации месторождений и низкой подтвержденности начальных геологических и извлекаемых запасов нефти [Медведев, 2010; Шубин и др., 2020].

Разработка викуловской свиты ведется более 30 лет, в результате чего накоплен огромный массив геолого-геофизической информации, включая проведенные сейсморазведочные работы и тысячи пробуренных скважин. Несмотря на это, примеров использования результатов количественной интерпретации данных сейсморазведки не так много, так как основным критерием для бурения скважин является структурный план (рис. 5, а). Поэтому наличие огромных объемов сейсмической и скважинной информации в пределах Красноленинского свода является настоящим вызовом не только для стандартных подходов количественной интерпретации данных сейсморазведки, но и для поиска перспективных неструктурных нефтегазоносных объектов при помощи нейронных сетей.

На изучаемом месторождении имеются 3D сейсмические данные во временной и глубинной областях, обработанные с использованием подхода интерпретационного сопровождения. Общая площадь сейсмической съемки составляет около 1700 км<sup>2</sup>, проектная кратность равна 72. Также на месторождении пробурено более 1500 скважин, в 1250 из кото-



**Рис. 5.** Структурные карты пластов викуловской свиты изучаемого месторождения с нанесенным контуром эталонного участка данных сейсморазведки: *а* – по кровле пласта  $VK_1$ ; *б* – по кровле пласта  $VK_{2-3}$ , осложненного отложениями врезанной речной долины. Здесь и на рис. 7 синие точки показывают положения скважин на площади.

рых посчитаны эффективные нефтенасыщенные толщины, а в 37 выполнена детальная поточечная интерпретация ГИС с непрерывной оценкой нефтенасыщения в изучаемом интервале (см. рис. 5). Часть викуловской свиты на месторождении осложнена врезанной речной долиной ( $VK_{2-3\text{врез}}$ ), отложения которой также нефтенасыщены (см. рис. 5, б).

Необходимо уточнить, что опробование описываемого метода иерархических нейронных сетей было выполнено по всей площади сейсмической съемки. Однако из соображений конфиденциальности результаты в данной работе показаны в ограниченной области, выделенной полигоном на рис. 5, с измененной геометрией съемки.

Основным целевым параметром для нейросетевого прогноза на изучаемом месторождении является нефтенасыщение порового пространства коллекторов викуловской свиты. Стоит отметить, что прогноз флюидонасыщения по данным сейсморазведки зача-

стую невозможен из-за множества факторов, включающих жесткость минерального скелета, низкую пористость пород-коллекторов и близкие по значениям упругие свойства нефти и воды. Вместе с тем в работе [Шубин и др., 2023] авторы показали влияние нефтенасыщения в интервале викуловской свиты на динамику волновой картины, выраженной наличием регрессионной связи эффективных нефтенасыщенных толщин со значениями амплитуд волнового поля для дальних удалений. Это создает предпосылки для прогноза нефтенасыщения по сейсмическим данным на всей площади исследования, в том числе с использованием нейронных сетей.

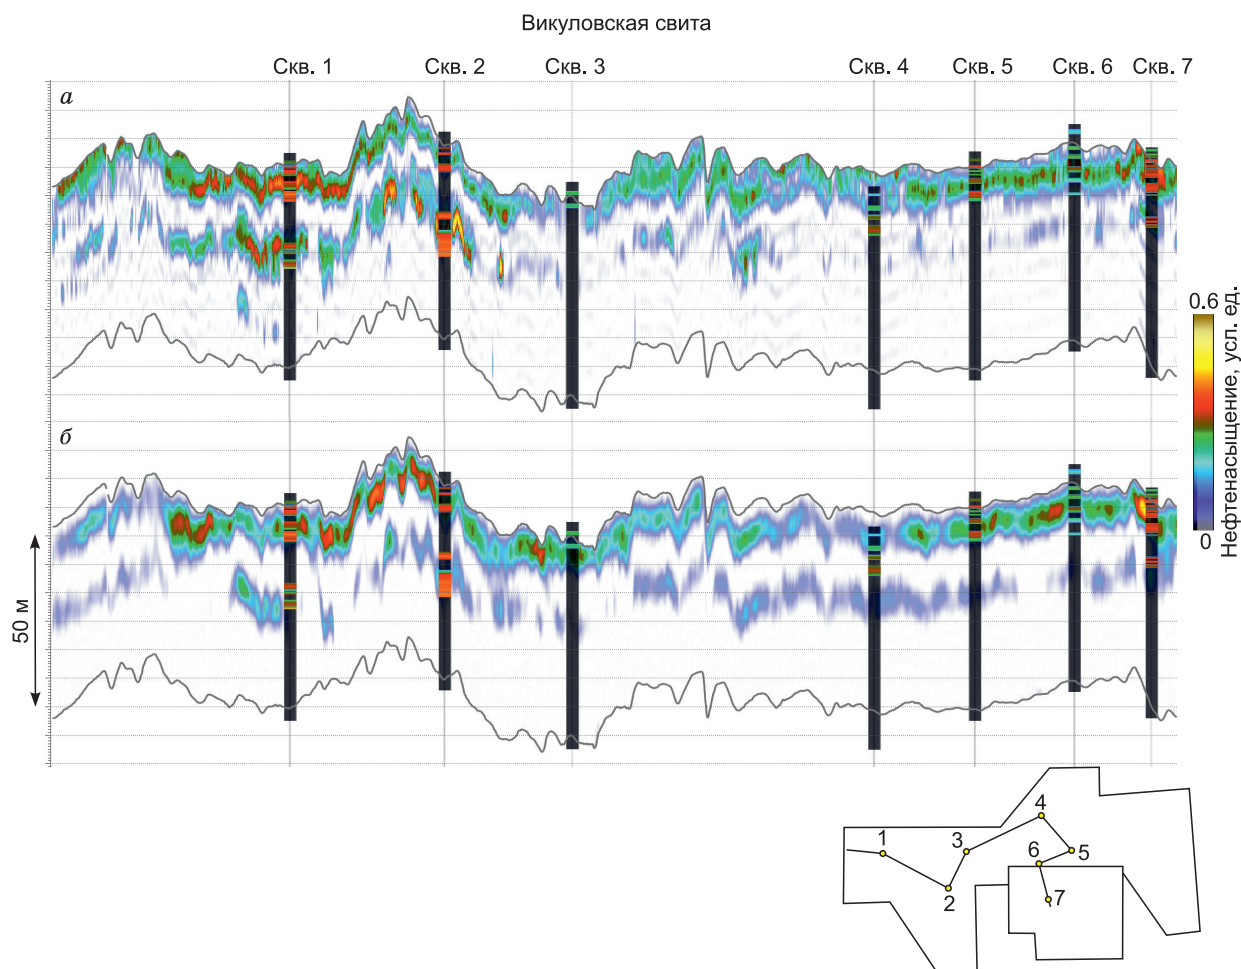
Обучающая выборка для описываемого в этой статье алгоритма иерархических нейронных сетей включает непрерывные кривые нефтенасыщения, полученные в 30 скважинах после детальной интерпретации данных ГИС (7 скважин использовались в качестве «слепых»), как прогнозный параметр, а также

наборы частично-кратных сумм со значениями средних углов  $5^\circ$ ,  $15^\circ$ ,  $25^\circ$ ,  $35^\circ$  и  $45^\circ$ , их амплитудные, амплитудно-частотные атрибуты и рассчитанные AVO-атрибуты (Amplitude Variation with Offset – зависимость изменения амплитуд отраженных волн от удаления) (интерсепт и градиент) как *сейсмический отклик* (см. рис. 1, блок 1). Для обучения иерархических нейронных сетей использовался алгоритм классификации Kohonen 1D с 30 «ближайшими соседями». Количество скрытых слоев соответствовало 5 с 15 нейронами на каждом скрытом слое.

Одной из основных проблем использования нейронных сетей при количественной интерпретации сейсморазведки является геологическое обоснование полученного прогноза. Зачастую математические оценки результата нейронных сетей показывают высокую степень и достоверность прогноза. Однако геологически осмыслить и интегрировать полученный результат в имеющуюся геологическую модель достаточно проблематично. Поэтому для сравнения и верификации предложенного иерархического ней-

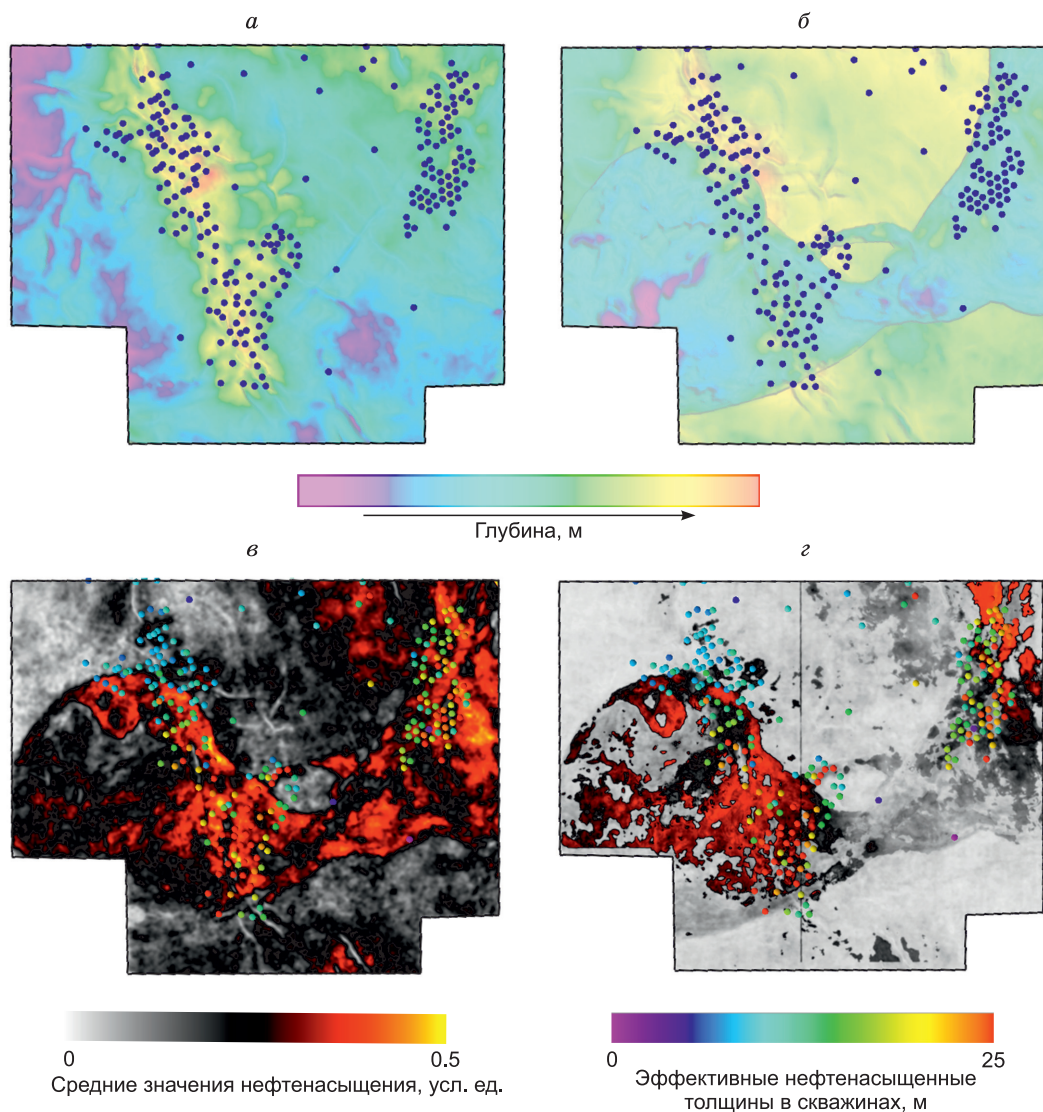
росетевого прогноза был использован результат оценки нефтенасыщения, полученный на изучаемом месторождении с использованием методики петроупругой инверсии [Шубин и др., 2020]. Стоит отметить, что петроупругая инверсия применялась авторами с тем же набором сейсмических и скважинных данных, на которых выполнялось опробование иерархических нейронных сетей. Полученные сейсмогеологические результаты были доложены и защищены в компаниях-недропользователях, а также представлены в научных публикациях [Шубин и др., 2020, 2023; Shubin et al., 2022].

На рисунке 6 показано сопоставление разрезов нефтенасыщения, рассчитанных с помощью иерархических нейронных сетей (см. рис. 6, а) и апостериорного среднего нефтенасыщения, полученного по методике петроупругой инверсии (см. рис. 6, б). Скважины, представленные на разрезах, в прогнозах обоих подходов не участвовали и использовались только в качестве проверочных («слепой тест») для верификации полученных результатов.



**Рис. 6.** Разрезы прогнозов нефтенасыщения, проходящие через «слепые» скважины: а – по результату иерархических нейронных сетей; б – по результату петроупругой инверсии. Здесь и на рис. 8 номера скважин на схеме соответствуют номерам скважин на разрезе. Вокруг скв. 7 указан контур полигона, по которому разрешена публикация результатов. Подробнее см. в тексте.





**Рис. 7.** Структурные карты пластов викуловской свиты: по кровле пласта  $BK_1$  (а); по кровле пласта  $BK_{2-3}$ , осложненного отложениями врезанной речной долины (б). Карты средних значений нефтенасыщения в интервалах  $BK_1$ – $BK_{2-3}$ : по результату петроупругой инверсии (в); по результату иерархических нейронных сетей (г).

На рисунке 7 представлены карты средних значений нефтенасыщения в интервалах  $BK_1$ – $BK_{2-3}$ , также рассчитанные по двум рассматриваемым методам.

Сравнения, приведенные на рис. 6, 7, показывают геологическую схожесть полученных результатов, что говорит об эффективности применения предложенного алгоритма иерархических нейронных сетей для решения поставленных геологических задач по данным сейсморазведки. Детальное сопоставление прогнозов нефтенасыщения, полученных по обоим рассматриваемым методам, в местах положения проверочных («слепых») скважин показано на рис. 8. Для более наглядного сравнения результаты приведены в едином масштабе. Анализ показал, что оба метода дали сопоставимые по ошибкам и точности результаты прогноза: общий коэффициент корреляции петро-

упругой инверсии составил 0.66, иерархических нейронных сетей – 0.71.

## ОБСУЖДЕНИЕ

Результаты опробования предложенного алгоритма на модельных и реальных данных показали, что иерархические нейронные сети являются достаточно эффективным и быстрым инструментом количественной интерпретации данных сейсморазведки.

Применение иерархических нейронных сетей на одном из месторождений Краснотинского свода Западной Сибири показало, что полученные результаты достаточно схожи с результатами петроупругой инверсии по количественным оценкам нефтенасыщения (см. рис. 8) и латеральным геологическим де-



Сопоставление этапов получения прогноза с использованием петроупругой инверсии и иерархических нейронных сетей

№ п/п	Этапы выполнения прогноза	Петроупругая инверсия	Иерархические нейронные сети
1	Построение объемной литолого-петрофизической модели по данным ГИС	+	+
2	Анализ петроупругих связей	+	+
3	Петроупругое моделирование	+	↓
4	Выполнение сейсмической синхронной инверсии	+	
5	Инверсия параметров петроупругой модели	+	
6	Петроупругая инверсия/нейросетевой прогноз	+	+
7	Интерпретация полученного результата	+	+

Примечание. Стрелка обозначает пропуск этапов, «+» – этап выполнять необходимо.

талям (см. рис. 6). Тем не менее значительным преимуществом разработанного алгоритма является скорость вычисления прогноза. Например, время расчета по всей изучаемой площади (1700 км<sup>2</sup>) в интервале викуловской свиты составило примерно 1 ч 30 мин. Расчет только петроупругой инверсии по имеющимся кубам акустического импеданса и отношения  $v_p/v_s$  составляет около 2 сут. Вычисления выполнялись на рабочей станции со следующими характеристиками: Intel Xeon CPU E5-2667 v4 3.20GHz, RAM 192 Gb, Nvidia Tesla M60x2.

Для более наглядного сопоставления этапы выполнения прогноза предложенного алгоритма иерар-

хических нейронных сетей и метода петроупругой инверсии представлены в таблице.

Также стоит отметить, что количество этапов при выполнении прогноза с использованием иерархических нейронных сетей значительно меньше, чем в классических методах динамической интерпретации сейсморазведки. Это существенно снижает вероятность субъективной человеческой ошибки в процессе нейросетевого прогноза по сравнению с такими многоэтапными методами, как сейсмическая амплитудная и петроупругая инверсии (см. таблицу).

Помимо направления количественной интерпретации сейсморазведки, предложенный метод иерар-

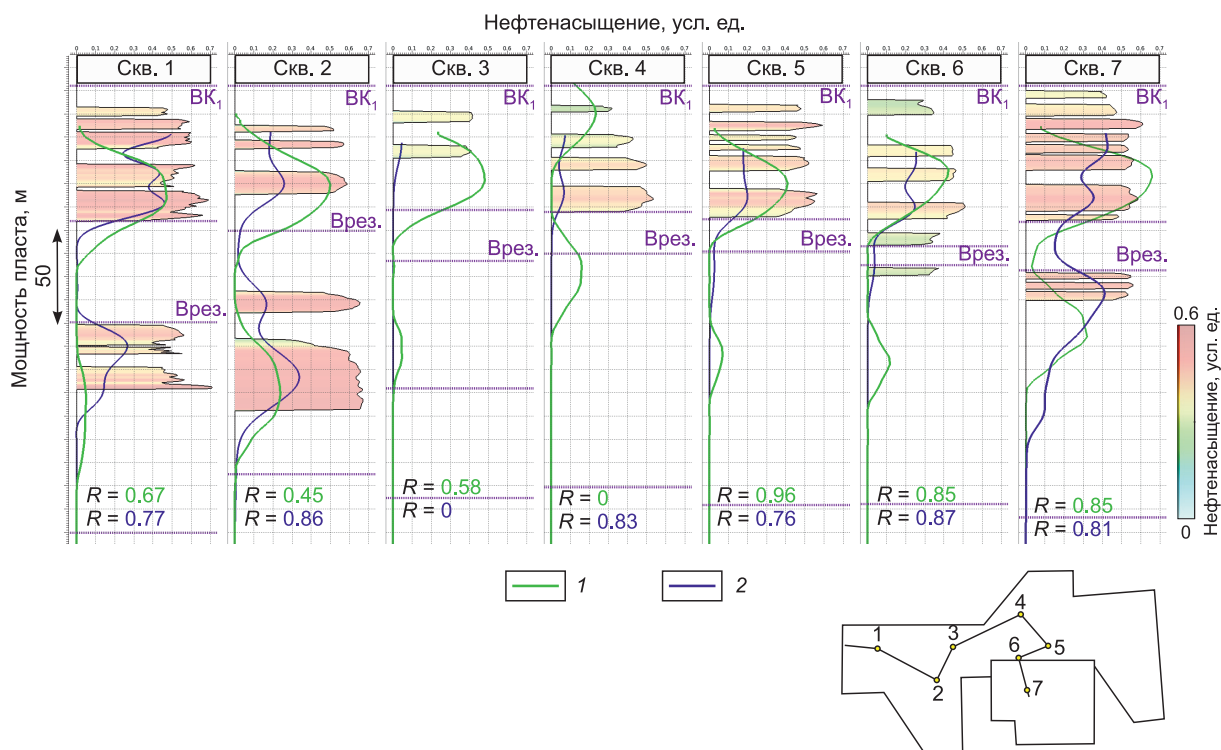


Рис. 8. Сопоставление прогнозов нефтенасыщения, полученных с помощью петроупругой инверсии и иерархических нейронных сетей, в проверочных («слепых») скважинах в едином общем масштабе. 1 — результат петроупругой инверсии, 2 — результат применения иерархических нейронных сетей. R — коэффициент корреляции, усл. ед. Врез. — обозначение стратиграфической отбивки, соответствующей врезанной речной долине.

хических нейронных сетей может быть использован в областях науки, отличных от нефтегазового сектора. Например, метод также тестировался и в задачах распознавания рукописных символов на известном наборе данных MNIST (Modified National Institute of Standards and Technology, США). База данных MNIST содержит 60 000 изображений рукописных символов с размером  $28 \times 28$  пикселей для обучения и 10 000 изображений для тестирования. Построение выполнялось по обучающему набору символов поискового кластерного дерева решений, которое использовалось для поиска подобных изображений из тестового набора. В случае использования полного массива обучения без разделения на кластеры, время поиска ближайших соседей составляло 80.41 мин с ошибкой распознавания 369 символов (3.69 %) для всех тестируемых символов. После построения поискового кластерного дерева решений, состоящего из десяти кластеров на каждом уровне и с глубиной дерева до пяти уровней, прогноз по тестовому набору выполнялся 0.12 мин, что в результате быстрее в 670 раз! Однако выросла и ошибка распознавания до 564 символов (5.64 %) из-за неоднозначности деления на кластеры.

## ЗАКЛЮЧЕНИЕ

Представленный в работе алгоритм иерархических нейронных сетей является эффективным инструментом количественной интерпретации данных сейсморазведки, который может быть использован как альтернатива или дополнение к классическим технологиям интерпретации при решении сложных геологических задач. Основные преимущества алгоритма заключаются в высокой скорости обучения, определении сейсмогеологических объектов с низкой степенью подобию, способности к генерализации и дообучению.

По сравнению с такими многоэтапными методами, как сейсмическая амплитудная инверсия и петроупругая инверсия, применение иерархических нейронных сетей позволяет выполнять одношаговые вычисления без использования целого ряда сложных

программных комплексов для получения промежуточных результатов. Это существенно снижает временные затраты при расчете целевых геолого-геофизических параметров, вероятность накопления ошибок при переходе от одного этапа количественной интерпретации к другому, а также повышает эффективность получаемого прогноза свойств коллекторов нефти и газа по скважинным и сейсмическим данным.

## БЛАГОДАРНОСТИ

Выражаем благодарность нашим коллегам из РГУ нефти и газа (НИУ) им. И.М. Губкина, МГУ им. М.В. Ломоносова, ПАО НК «Роснефть» и ПАО «Лукойл» за возможность опробования разработанного алгоритма иерархических нейронных сетей на реальных данных и публикации полученных результатов.

## ЛИТЕРАТУРА

- Медведев А.Л. (2010). Аптские врезанные речные долины Каменной площади Западной Сибири: региональные аспекты нефтегазоносности // Нефтегазовая геология. Теория и практика, т. 5 (3), с. 1–27.
- Шубин А.В., Кляжников Д.В., Рыжков В.И. (2020). Петроупругая инверсия: прогноз пористости и флюидонасыщения викуловской свиты // Геофизика, № 6, с. 31–41.
- Шубин А.В., Кляжников Д.В., Рыжков В.И. (2023). О возможности прогноза нефтенасыщенности терригенного коллектора по сейсмическим данным // Геомодель 2023. Сборник материалов 25-й юбилейной научно-практической конференции по вопросам геологоразведки и разработки месторождений нефти и газа. М., Геомодель, с. 243–246.
- Kohonen T. (2012). Self-Organizing Maps. Springer Berlin, Heidelberg, 502 p., doi: [10.1007/978-3-642-56927-2](https://doi.org/10.1007/978-3-642-56927-2).
- Malkov Yu.A., Yashunin D.A. (2018). Efficient and robust approximate nearest neighbor search using hierarchical navigable small world graphs // IEEE Trans. Pattern Anal. Mach. Intel., v. 42 (4), p. 824–836, doi: [10.1109/TPAMI.2018.2889473](https://doi.org/10.1109/TPAMI.2018.2889473).
- Priezzhev I.I., Veeken P.C.H., Egorov S.V., Nikiforov A.N., Strecker U. (2019). Seismic waveform classification based on Kohonen 3D neural networks with RGB visualization // First Break, v. 37 (2), p. 37–43, doi: [10.3997/1365-2397.2019012](https://doi.org/10.3997/1365-2397.2019012).
- Shubin A., Klyazhnikov D., Ryzhkov V. (2022). Rock Physics inversion for fluid saturation and porosity prediction // Second EAGE Conference on Seismic Inversion, v. 2022 (1), p. 1–5, doi: [10.3997/2214-4609.202229011](https://doi.org/10.3997/2214-4609.202229011).