

УДК 550.3

DOI: 10.46698/VNC.2026.38.50.001

Оригинальная статья

Идентификация сейсмофациальных тел на основе частотно-временных атрибутов и самоорганизующихся карт Кохонена

Р.И. Меликов[✉], Г.Р. Бабаев[✉]

Институт геологии и геофизики, Министерство науки и образования Азербайджанской Республики, Республика Азербайджан, AZ1073, г. Баку, пр. Г. Джавида, 119,
e-mail: ruslan.m08@outlook.com, babayev74@gmail.com

Статья поступила: 13.01.2026, доработана: 11.05.2026, принята к публикации: 14.05.2026

Резюме: Актуальность работы обусловлена необходимостью повышения надёжности и воспроизводимости сейсмофациальной интерпретации в сложных условиях осадконакопления, где традиционные методы, основанные преимущественно на амплитудных атрибутах и ручном подборе частотных полос, нередко оказываются недостаточно эффективными при выявлении слабовыраженных литолого-стратиграфических изменений и существенно зависят от субъективных решений интерпретатора. **Целью исследования** является разработка и апробация интегрированного алгоритма трёхмерной кластеризации сейсмических фаций, обеспечивающего автоматизированное выделение объёмных геологических тел на основе многополосных частотных атрибутов сейсмических данных. Методами исследования служат вейвлет-преобразование, реализованное в форме непрерывного вейвлет-преобразования, для спектрального разложения сейсмического сигнала и формирования набора частотно-временных атрибутов, а также использования карт Кохонена для кластеризации многомерных данных с сохранением топологической структуры признакового пространства. Обученная самоорганизующаяся карта далее применяется к трёхмерному сейсмическому кубу, обеспечивая выделение сейсмофациальных тел. **Результаты исследования** на материалах Южно-Каспийского бассейна, показывают, что предложенный подход позволяет эффективно идентифицировать меандрирующие русловые тела, прирусловые валы и стратиграфические границы, обеспечивая построение трёхмерных фациальных моделей. В целом предложенный метод снижает интерпретационную субъективность, повышает надёжность и воспроизводимость результатов и может быть эффективно использован при решении задач коллекторской характеристики, планировании геологоразведочных работ и оценке запасов углеводородов.

Ключевые слова: сейсмофации, сейсмофациальный анализ, геологические тела, частотно-временные атрибуты, непрерывное вейвлет-преобразование, самоорганизующиеся карты Кохонена, обучение без учителя, машинное обучение.

Для цитирования: Меликов Р.И., Бабаев Г.Р. Идентификация сейсмофациальных тел на основе частотно-временных атрибутов и самоорганизующихся карт Кохонена. *Геология и геофизика Юга России*. 2026. 16(2): 71–84. DOI: 10.46698/VNC.2026.38.50.001

DOI: 10.46698/VNC.2026.38.50.001

Original paper

Identification of seismic facies objects using time-frequency attributes and self-organizing neural networks

R.I. Malikov^{}, G.R. Babayev^{}

Institute of Geology and Geophysics, Ministry of Science and Education of the Republic of Azerbaijan, 119 H. Javid Ave., Baku AZ1073, Azerbaijan,
e-mail: ruslan.m08@outlook.com, babayev74@gmail.com

Received: 13.01.2026, revised: 11.05.2026, accepted: 14.05.2026

Abstract: The relevance of this work is driven by the need for more reliable and reproducible seismic facies interpretation in complex depositional settings, where conventional methods are primarily based on amplitude attributes and manual selection of frequency bands that are often insufficient for detecting subtle geological variations and largely depend on subjective interpreter decisions. **Aim of the study** is to develop and validate an integrated workflow for three-dimensional seismic facies clustering that enables automated delineation of volumetric geological bodies using multi-frequency attributes derived from seismic data. **Research methods** include application of continuous wavelet transform for spectral decomposition of the seismic signal that creates a multi-frequency feature data set, as well as the use of Kohonen maps for clustering high-dimensional data while preserving their topological relationships. The trained self-organizing map is then applied to the 3D seismic volume, enabling delineation and extraction of volumetric geological objects. **Results** show that the proposed approach effectively identifies meandering channel bodies, levee deposits, and stratigraphic boundaries, when applied to data from the South Caspian Basin and provides three-dimensional facies modeling. Overall, the method reduces interpretational subjectivity, improves the reliability and reproducibility of results, and offers advantages for reservoir characterization, exploration activities, and resource estimation.

Keywords: seismic facies, seismofacial analysis, geological bodies, frequency-time attributes, continuous wavelet transform, Kohonen self-organizing maps, unsupervised learning, machine learning.

For citation: Malikov R.I., Babayev G.R. Identification of seismic facies objects using time-frequency attributes and self-organizing neural networks. *Geologiya i Geofizika Yuga Rossii = Geology and Geophysics of Russian South*. (in Russ.). 2026. 16(2): 71–84. DOI: 10.46698/VNC.2026.38.50.001

Введение

Точная классификация сейсмofаций является основополагающим этапом для интерпретации недр, поскольку она дает представление о процессах осадконакопления, распределении литологических типов и потенциале коллектора [Posamentier, Kolla, 2003; Interpretation ..., 2011; Samakinde et al., 2020; Owusu et al., 2025]. Процедура предполагает объединение сейсмических откликов на основе их амплитуды, непрерывности и частотных свойств для выделения таких седиментационных элементов, как русловые тела, прирусловые валы, веерообразные песчано-алевритовые образования и карбонатные сооружения [Chopra, Marfurt, 2007]. Кроме разведки углеводородов, подобные классификации применяются для анализа бассейнов [Nanda, 2021] и оценки геологических рисков [Sukmono et al., 2017].

Традиционный подход к интерпретации сейсмических фаций основывался на визуальном анализе формы и амплитуд отражений с привлечением данных скважин [Interpretation ..., 2011]. Внедрение сейсмических атрибутов позволило перейти к ко-

личественному анализу более высокого уровня, учитывающему амплитуду, кривизну и фазу сейсмического отклика [Chopra, Marfurt, 2007]. Алгоритмы, ориентированные главным образом на амплитудные характеристики, часто не выявляют мелкие стратиграфические изменения, особенно если они выражаются в частотной области. В областях со сложной стратиграфической структурой сейсмические отклики отличаются высокой неоднородностью и неоднозначностью, что приводит к тому, что небольшие геологические различия могут оставаться нераспознанными при использовании традиционных амплитудно-ориентированных методов интерпретации.

Методы спектрального разложения, такие как оконное преобразование Фурье (ОПФ) [Partyka et al., 1999], S-преобразование и вейвлет-преобразование (ВП) [Castagna et al., 2003; Sinha et al., 2005], существенно преобразили стратиграфический анализ, позволяя представлять сейсмические данные в частотно-временной области. ОПФ являлось одним из первых распространённых методов, но постоянный размер окна ограничивает одновременно точность по времени и по частоте. В отличие от него, ВП стало одним из наиболее распространенных инструментов в стратиграфическом анализе [Castagna et al., 2003; Sinha et al., 2005]. Его способность обнаруживать тонкие спектральные изменения используется для выявления русловых тел, картирования карбонатных рифов и определения аномалий, связанных с углеводородным распределением в различных осадочных обстановках [Kazemeini et al., 2008; Von Hartmann et al., 2012]. Тем не менее, хотя эти методы повышают разрешающие способности сейсмических данных, они генерируют многомерные наборы данных, что затрудняет их визуальную и ручную интерпретацию.

В то же время применение автоматизированных технологий, машинного обучения и нейросетевых алгоритмов при построении геологических моделей рассматривается как одно из перспективных направлений повышения достоверности интерпретации геолого-геофизических данных [Потехин, Галкин, 2023; Эзирбаев, 2025]. В частности, методы машинного обучения зарекомендовали себя как эффективные инструменты для классификации сейсмических фаций. Самоорганизующиеся карты Кохонена (СОК), основанные на алгоритмах кластеризации без учителя, снижают размерность данных, проецируя многомерные векторы признаков на двумерную нейронную сетку и выявляя структуры данных, которые могут оставаться незамеченными при традиционной интерпретации [Kourki, Riahi, 2014; Roden et al., 2015; Zhao et al., 2015; Приезжев и др., 2020; Никулин, Самсонов, 2021]. Изначально применение самоорганизующихся карт ограничивалось двумерным анализом отдельных горизонтов, что ограничивало геологическую интерпретацию стратиграфическими срезами. Современные методы расширяют СОК на трёхмерные сейсмические объёмы, позволяя формировать геологические тела, более полно отражающие строение и связность коллекторов. Однако вопрос об оптимальном объединении спектральных данных сейсмического сигнала и алгоритмов машинного обучения для сохранения интерпретируемости всё ещё остаётся открытым. Подобный подход к интеграции спектрального разложения с методами обучения без учителя был реализован в исследовании Меликова и Бабаева [Malikov, Babayev, 2025]. В этой работе частотные атрибуты, полученные с использованием непрерывного вейвлет-преобразования (НВП), были совместно проанализированы с кластеризацией СОК, что позволило выделить русловые системы и фациальные границы в Южно-Каспийском бассейне (ЮКБ). Результаты их работы показали, что сочетание многополосного разложения с классификацией без учителя улучшает выявляемость меандрирующих русел и внутренней структурной изменчивости, одновременно уменьшая субъективность интерпретации. Основываясь на этих выводах, настоящее исследование расширяет данный подход от анализа отдельных горизонтов к полноценной объемной кластеризации, позволяющей извлекать трехмерные геологические тела и выполнять количе-

ственное фациальное моделирование. Такой переход предоставляет более целостное понимание строения коллектора и характера его связанности.

По сравнению с альтернативными методами, СОК обладают рядом специфических преимуществ. Так, хотя алгоритм k -средних отличается высокой вычислительной эффективностью, он предполагает сферичность кластеров и одинаковую дисперсию, что нередко чрезмерно упрощает представление об изменчивости сейсмических фаций [Zhao et al., 2015]. Метод главных компонент (МГК) широко используется для снижения размерности, но фиксирует лишь линейные зависимости и может пропускать нелинейные связи, имеющие ключевое значение для стратиграфической интерпретации [Das et al., 2016]. Подходы с учителем, такие как метод опорных векторов или случайные леса, требуют обширных размеченных данных, которые редко присутствуют в сейсмических задачах, а их результаты могут наследовать субъективность интерпретатора [Zhu et al., 2022]. За последнее десятилетие глубокие нейронные сети, особенно сверточные нейронные сети, продемонстрировали высокий потенциал в выявлении сложных пространственных закономерностей; однако им свойственны высокая потребность в размеченных данных, значительные вычислительные затраты и ограниченная интерпретируемость из-за так называемой природы «чёрного ящика» [Rudin, 2019]. На этом фоне СОК выделяются возможностью объединять уменьшение размерности, обучение без учителя и наглядность результатов, что делает их особенно удобными для анализа сейсмических фаций в условиях отсутствия размеченных данных [Zhu et al., 2022; Samuel et al., 2025].

В работе предложено решение поставленных задач, основанное на комплексном использовании спектрального разложения сейсмического сигнала методом НВП и кластеризации многомерных данных с применением СОК, что обеспечивает построение трёхмерных моделей сейсмофаций. Апробация разработанного алгоритма на материалах ЮКБ показала, что формируемые фациальные кластеры могут быть представлены в виде карт распределения и интерпретированы как трёхмерные сейсмогеологические тела. Полученные результаты свидетельствуют о том, что интеграция частотно-временного анализа с методами обучения без учителя способствует повышению разрешающей способности геологической интерпретации и снижению влияния субъективного фактора. Это обеспечивает более надёжную основу для прогноза коллекторских свойств и оценки запасов углеводородов.

Материалы и методы

Предложенный подход сочетает многополосное спектральное разложение с кластеризацией, основанной на СОК, что позволяет сформировать объёмную классификацию сейсмических фаций. Этот метод развивает более ранние решения, в которых НВП совместно с СОК применялись для кластеризации фаций по горизонтам в пределах ЮКБ [Malikov, Babayev, 2025].

Процесс начинается с загрузки трехмерного сейсмического объема и доступных структурных или стратиграфических горизонтов. В отличие от классических подходов, которые зависят от точной интерпретации горизонтов для корректного извлечения атрибутов, эта методика допускает использование лишь приблизительных ограничивающих поверхностей, при условии, что они охватывают требуемый стратиграфический интервал.

На предварительном этапе могут применяться методы, такие как автоматическая регулировка усиления (АРУ), для уменьшения амплитудной изменчивости, вызванной артефактами съемки или эффектами, связанными с присутствием углеводородов [Yilmaz, 2001]. Эта подготовка выравнивает амплитудные колебания, обеспечивая, чтобы последующая кластеризация основывалась преимущественно на геологических характеристиках, а не на особенностях сбора данных или влиянии флюидов.

После предварительной подготовки объема применяется спектральное разложение для генерации узкополосных частотных представлений сейсмических данных. Техника НВП выбрана из-за ее гибкости и лучшего частотно-временного разрешения. Для сейсмической трассы, $s(t)$, НВП определяется как:

$$X(a, b) = \frac{1}{|a|^{\frac{1}{2}}} \int_{-\infty}^{\infty} s(t) \psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

где a – параметр масштаба (обратно пропорциональный частоте), $\psi(t)$ – материнский вейвлет, b – сдвиг во времени. В данном алгоритме выбран вейвлет Рикера [Wang, 2015] из-за его сходства с сейсмическими вейвлетами с нулевой фазой.

Изменение параметра масштаба a в НВП позволяет разлагать сейсмический сигнал на серию частотных полос. Например, разложение от 5 Гц до 60 Гц с шагом 2 Гц: этот широкий диапазон обеспечивает представление как крупномасштабных стратиграфических объектов, таких как широкие клиноформы (косозалегающие слоистые структуры осадочных пород), так и мелкомасштабных, таких как тонкие русловые отложения (осадочные породы, накопившиеся в пределах речных или подводных каналов) [Owusu et al., 2025]. Каждое разложение создает отдельный амплитудный объем, соответствующий конкретной частотной полосе, и вместе они формируют многомерный набор частотно-зависимых амплитуд. Результаты спектрального анализа преобразуются для дальнейшей обработки таким образом, чтобы каждый отсчёт трехмерного сейсмического куба представлялся многомерным вектором спектральных амплитуд. Данные вектора объединяются в кластеры с использованием алгоритма СОК, представляющего собой двумерную сетку нейронов, где каждый нейрон имеет вектор весов такой же размерности, как и входные данные.

Обучение СОК происходит итеративным путем. Изначально каждому нейрону в сетке СОК присваивается случайный вектор весов, совпадающий по размерности с входными данными. На каждой итерации выбирается случайный входной вектор, который затем сравнивается со всеми нейронами для определения лучшей единицы соответствия – нейрона, чей вектор весов максимально близок к входному. Для количественной оценки схожести используется метрика Евклидова расстояния:

$$d_j = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (2)$$

где n – количество частотных диапазонов, x_i – компоненты входного вектора, w_{ji} – веса нейрона j .

После определения лучшей единицы соответствия его вектор весов корректируется для большего сходства с входным вектором, а соседние нейроны обновляются в меньшей степени согласно функции соседства:

$$w_i(t+1) = w_i(t) + \lambda(t)h(t, w_i(t))[x - w_i(t)] \quad (3)$$

где $\lambda(t)$ – скорость обучения, h – функция соседства, которая экспоненциально уменьшается с расстоянием от лучшей единицы соответствия. В ходе последовательных итераций скорость обучения и радиус соседства уменьшаются, что позволяет СОК постепенно сходиться к стабильному состоянию, которое отражает спектральную изменчивость набора данных.

В результате обучения СОК формируется двумерная карта, отражающая разнообразие спектральных шаблонов, содержащихся в данных, при этом каждый нейрон представляет собой обобщенный частотный профиль. Далее расчетные ячейки трехмерного сейсмического куба классифицируются по принципу наилучшего соответствия их частотно-зависимого амплитудного отклика вектору весов нейрона. В итоге получается трёхмерный сейсмический объём с кластеризацией, где каждая расчетная ячейка сейсмического куба отнесена к конкретному классу фаций.

Результаты и обсуждение

Предложенный алгоритм был применен к сейсмическому набору данных после суммирования из ЮКБ, характеризующегося быстрым накоплением отложений, сложной архитектурой отложений и значительным потенциалом углеводородов. Географически ЮКБ расположен к востоку от Азербайджана, к западу от Туркменистана и к северу от Ирана; он состоит, в основном, из отложений третичного возраста с толщиной осадков до 20 км, характеризуется низкой уплотненностью, низким геотермальным градиентом и аномально высокими пластовыми давлениями [Smith-Rouch, 2006; Kaz'min, Verzhbitskii, 2011].

Структурно-стратиграфическая основа бассейна сформирована обширным дельтовым поступлением, проседанием дна и выраженной тектонической активностью с миоцена. В этот период основной приток отложений обеспечивали системы Палео-Амударья и Палео-Волга, а также реки Палео-Кура и Палео-Сефид-Руд. Несмотря на то, что в настоящее время бассейн является глубоководным, значительная часть отложений плиоцена и раннего плейстоцена формировалась в условиях мелководного осаднения, завершающей стадией формирования которого стал региональный клиноформный горизонт Абшеронского этапа в нижнем плейстоцене, последовательность, представленная в основном сланцами с прослойками мергеля и песчаников. В общем, ЮКБ характеризуется сложным геодинамическим строением, высокой мощностью осадочного чехла и значительным нефтегазовым потенциалом, что подтверждается результатами комплексного анализа геофизических, сейсмологических и геодинамических данных [Yetirmishli et al., 2025].




Рис. 1. Сетка СОК с 10×10 топологией, где каждая ячейка – это обобщенная амплитудно-частотная характеристика, полученная после обучения. Все графики имеют общие оси x и y /

Fig. 1. SOM grid with 10×10 topology, where each cell is a generalized amplitude-frequency characteristic obtained after training. All graphs have common x and y axes

В рамках данного геологического контекста предложенный алгоритм был применен для генерации кластерных сейсмических объёмов и выделения трёхмерных фациальных тел, что позволяет получить более детальное стратиграфическое и коллекторское описание. В пределах исследуемой области на основе сейсмических данных было выявлено, что в целевом стратиграфическом интервале преобладают дельтовые и речные системы. Спектральное разложение в диапазоне частот 10–50 Гц с шагом 2 Гц, за которым последовала обработка с помощью СОК, позволило получить сетку 10×10 с обобщёнными частотными закономерностями (рис. 1). Средний частотный спектр сейсмических данных в пределах целевого интервала использовался в качестве основы для определения частотного диапазона, заданного полосой пропускания на уровне -10 дБ (рис. 2). Для отображения результатов СОК с большим количеством кластеров используется двумерная цветовая схема. В этой цветовой схеме каждому кластеру присваивается уникальный цвет, отражающий полученный обобщённый образец амплитудно-частотного изменения сейсмического сигнала, который он представляет в пространстве СОК. Далее обученная модель была применена к целевому сейсмическому объёму, преобразуя отдельные точки выборки в соответствующие кластеры СОК. Полученные кластеры визуализируются посредством окрашивания каждой расчетной ячейки сейсмического куба в цвет, соответствующий его кластеру, что позволяет выявлять пространственные структуры и взаимосвязи.




Рис. 2. Средний частотный спектр сейсмических данных для области исследования с красной пунктирной линией, указывающей полосу пропускания на уровне -10 дБ /

Fig. 2. Mean frequency spectrum of seismic data for the area of interest with a red dotted line indicating the seismic bandwidth at -10 dB

На рисунке 1, демонстрирующем сетку СОК, наблюдаются систематические изменения в спектральных характеристиках кластеров. В частности, доминирующая частота в целом возрастает снизу вверх по сетке, а также справа налево, тогда как максимальная амплитуда уменьшается от правого верхнего угла к левому нижнему. При этом частотно-амплитудные структуры постепенно изменяются от узла к узлу, отражая непрерывный спектр осадочных и литологических вариаций, присутствующих в сейсмических данных. Такое распределение в пространстве СОК показывает, как алгоритм сохраняет геологическую непрерывность, преобразуя сейсмический сигнал в значимые кластеры, которые затем могут быть обратно интегрированы в сейсмический объём. Анализируя карту СОК вместе с кластеризованным объёмом, интерпретаторы получают возможность напрямую сопоставлять спектральные атрибуты с геологическими фациями, превращая абстрактные частотные данные в инструмент для классификации фаций и изучения процессов осадконакопления.




Рис. 3. Сравнение профилей временного сейсмического разреза (а) с результатами кластеризации объёма СОК (b). Стрелки указывают кластеры, соответствующие руслам /

Fig. 3. Comparison of time seismic section profiles (a) and the results of SOM volume clustering (b). Arrows indicate clusters corresponding to channels

На рисунке 3 представлено сопоставление сейсмического временного профиля с кластеризованным отображением исследуемой зоны. На сейсмическом профиле отражения имеют переменную амплитуду, что затрудняет интерпретацию тонких особенностей осадочных пород и усложняет стратиграфическую интерпретацию. Напротив, кластерное представление, полученное с помощью предлагаемой методики, выделяет фации в отдельные кластеры, которые соответствуют геологически последовательным моделям. Стрелки на рисунках указывают на систему русел, характеризующуюся сейсмическими откликами высокой амплитуды, которые четко разделены на отдельные кластеры. Сопоставление сейсмического разреза с его кластеризованным представлением иллюстрирует способность методики преобразовывать сложные сейсмические сигналы в удобную для интерпретации модель фаций.

На рисунке 4 на картах кластеров отчётливо прослеживаются извилистые русловые тела с выраженной меандровой формой и преимущественной ориентацией с севера на юг в обеих основных системах русел.




Рис. 4. Стратиграфические карты, извлеченные из кластеризованного сейсмического объема после применения СОК: (а) первая стратиграфическая единица; (b) вторая стратиграфическая единица /

Fig. 4. Stratigraphic maps extracted from the clustered seismic volume after the SOM application: (a) first stratigraphic unit; (b) second stratigraphic unit

Включение высокочастотных компонентов повышает детализацию этих структур, позволяя более чётко выделять мелкие притоки. Существенным преимуществом

кластерного подхода является его способность выявлять чёткие границы фаций, что обеспечивает точное определение границ русел. В то же время метод сохраняет внутреннюю неоднородность русел, что является ключевым для точной оценки объёмов. Такие особенности позволяют получить более детальное представление о строении русловых тел и распределении фаций, подчёркивая ценность данного подхода для геологического анализа.

В итоге, объединяя кластеры, соответствующие фациям русловых тел, создаётся единый класс русел, который можно ясно выделить на фоне окружающих осадочных фаций (рис. 5). Такая интеграция позволяет извлечь непрерывные системы русел из кластеризованного объёма, эффективно отделяя их от пойменных, прируслово-вальных и отложений с низкой коллекторской способностью. Полученная классификация служит основой для построения трёхмерных геологических тел, отражающих структуру русел. Эти тела демонстрируют как пространственное распределение, так и вертикальные схемы осадконакопления русел, обеспечивая объёмное представление их характеристик на масштабе месторождения.

Помимо точного выделения русел и пойменных фаций, предложенная методика продемонстрировала способность выявлять переходные зоны, внутреннюю неоднородность русловых тел и тонкие границы осадков, которые обычно остаются незамеченными на традиционных сейсмических разрезах. Трёхмерное извлечение русловых тел демонстрирует практическую ценность метода для моделирования пластов и оценки запасов, предоставляя интерпретаторам геологически согласованные характеристики, пригодные для непосредственной количественной оценки. Для обеспечения геологической достоверности рабочий процесс требует внимательного подбора параметров, таких как диапазон частот, размер сетки СОК и этап интеграции после кластеризации. Несмотря на то, что данный метод уменьшает субъективность интерпретатора благодаря автоматизации классификации фаций, участие эксперта-геолога по-прежнему необходимо для проверки результатов и интеграции сгруппированных геологических тел в модели недр. Эти результаты подчёркивают, что кластеризация на основе машинного обучения не заменяет геологическую интерпретацию, а выступает её дополнением, повышая эффективность, воспроизводимость и точность анализа.




Рис. 5. Извлеченные трехмерные русловые тела из кластеризованного объема СОК.

Различные цвета обозначают отдельные русловые системы /

Fig. 5. Extracted three-dimensional channel geological bodies from the clustered SOM volume.

Different colors indicate separate channel systems

Интеграция НВП и СОК, представленная в данном исследовании для трёхмерной классификации сейсмических фаций, формирует устойчивый и результативный метод количественной оценки коллекторских свойств. Предложенная методика позволяет эффективно выявлять тонкие стратиграфические вариации в сложных осадочных обстановках, включая ЮКБ. Результаты демонстрируют три существенных преимущества по сравнению с существующими подходами: более высокое геологическое разрешение, уменьшение субъективности интерпретации и возможность количественного описания геологических тел.

Повышенное геологическое разрешение очевидно при сравнении исходных сейсмических данных и объема, сгруппированного с помощью СОК (рис. 3). Традиционные сейсмические профили, хотя и показывают широкие отражающие структуры, маскируют мелкомасштабную архитектуру речно-дельтовых систем. В отличие от этого, кластеризация СОК, обученная на многомерном массиве частотно-зависимых амплитуд из НВП, успешно разделяет отдельные сейсмические фации. Стрелки на рисунке 3 четко обозначают системы каналов, которые визуальнo неразличимы в необработанных сейсмических данных. Это является прямым следствием способности НВП выявлять тонкие спектральные изменения, связанные с вариациями литологии, толщины и содержания жидкости, а также способности СОК сгруппировать эти многомерные признаки в интерпретируемые классы. Полученная фациальная модель представляет собой не просто интерпретацию исходных данных, а отражает реальную геологическую архитектуру, которую было бы крайне трудно воспроизвести вручную или посредством базового атрибутивного анализа.

Ручная интерпретация фаций по своей сути субъективна, поскольку опирается на опыт интерпретатора и ограниченное количество визуальных атрибутов. Алгоритм СОК, напротив, обеспечивает объективную и воспроизводимую классификацию каждой расчетной ячейки трехмерного сейсмического куба на основе его всестороннего спектрального профиля. Систематические вариации частотно-амплитудных характеристик вдоль сетки СОК (рис. 1) отображают непрерывный спектр геологических изменений в бассейне, от высокоамплитудных русловых заполнений до низкоамплитудных пойменных отложений.

Эта классификация без учителя существенно снижает вероятность пропуска мелких, но важных стратиграфических деталей и обеспечивает согласованность как между крупными массивами данных, так и между разными интерпретаторами. Несмотря на то, что окончательное геологическое обозначение кластеров всё ещё требует экспертной оценки, предварительная кластеризация, основанная на данных, формирует надёжную и объективную основу для дальнейшей интерпретации.

В итоге, наиболее значимым практическим результатом применения этой методологии является возможность извлечения трехмерных геотел непосредственно из кластеризованного объема (рис. 5). В отличие от двухмерных горизонтальных срезов (рис. 4), которые лишь частично передают пространственную непрерывность, трёхмерные геологические тела позволяют полностью отразить сложную структуру русловых тел, их наложение, извилистость и степень связности. Такие объёмные представления могут непосредственно использоваться при построении статических и динамических моделей месторождений. Возможность количественно оценивать размеры, извилистость и взаимные связи этих тел формирует более точную основу для расчёта запасов и выбора оптимальных схем размещения скважин.

При рассмотрении результатов следует учитывать существующие ограничения и направления для дальнейших исследований. Эффективность рабочего процесса во многом определяется правильным подбором параметров, таких как диапазон частот для НВП и размеры сетки СОК. В настоящем исследовании средний анализ частот-

ного спектра (рис. 2) служит эмпирической основой для их выбора, однако последующие работы могут сосредоточиться на разработке более сложных методов оптимизации этих параметров.

Заключение

В настоящей работе представлен алгоритм объёмной классификации сейсмофаций, основанный на интеграции НВП и СОК. Использование указанных методов обеспечивает переход от качественной интерпретации сейсмических данных, базирующейся на амплитудных атрибутах, к количественной интерпретации на основе спектральных (частотно-временных) атрибутов сейсмического сигнала.

Апробация метода на материалах ЮКБ показала его высокую эффективность при изучении строения руслово-дельтовых комплексов. НВП обеспечивает спектральное разложение сейсмического сигнала с формированием системы частотно-временных атрибутов, тогда как СОК реализует кластеризацию многомерных данных с сохранением их топологической структуры и выделением геологически интерпретируемых сейсмофаций. Применение предложенного подхода способствует повышению разрешающей способности сейсмических данных и позволяет выявлять тонкие литолого-стратиграфические элементы, включая различные типы русловых тел и ассоциированные с ними отложения, слабо выраженные при традиционной интерпретации.

Автоматизированный характер кластеризации, основанный на применении СОК, снижает влияние субъективного фактора интерпретатора и обеспечивает воспроизводимость результатов в пределах всего сейсмического объёма. Это создаёт надёжную основу для последующего геологического анализа. Важным результатом является возможность количественной характеристики трёхмерных сейсмофациальных тел, адекватно отражающих внутреннее строение резервуара, включая его связность и вертикальную неоднородность. Полученные геологические тела могут рассматриваться как самостоятельный результат интерпретации и использоваться при построении геологических и гидродинамических моделей залежей углеводородов, что способствует повышению достоверности оценки запасов и эффективности проектирования разработки месторождений.

Литература

1. Никулин И.И., Самсонов А.А. Нейросетевой кластерный анализ площадных геофизических данных рудоносного Хибино-Ловозёрского вулcano-плутонического комплекса (Кольский п-ов) методом самоорганизующихся карт Кохонена // Геофизические исследования. – 2021. – Т. 22. № 1. – С. 25–39. DOI: 10.21455/gr2021.1-2.
2. Потехин Д.В., Галкин С.В. Применение технологии машинного обучения при моделировании распределения литотипов на пермокарбоновой залежи нефти Усинского месторождения // Записки Горного института. – 2023. – Т. 259. – С. 41–51. DOI: 10.31897/PMI.2022.101.
3. Приезжев И.И., Васильев М.А., Петренко Е.Н. Построение прогнозных карт эффективных газонасыщенных толщин по форме сейсмического сигнала на основе нейронных сетей Кохонена // Геофизика. – 2020. – № 6. – С. 49–53.
4. Эзирбаев Т.Б. Нижнемеловая залежь Старогрозненского нефтегазового месторождения как объект геологического моделирования // Геология и геофизика Юга России. – 2025. – Т. 15. № 3. – С. 239–254. DOI: 10.46698/VNC.2025.27.39.001.
5. Castagna J.P., Sun S., Siegfried R.W. Instantaneous spectral analysis: Detection of low-frequency shadows associated with hydrocarbons // The Leading Edge. – 2003. – Vol. 22. No. 2. – pp. 120–127. DOI: 10.1190/1.1559038.
6. Chopra S., Marfurt K.J. Seismic attributes for prospect identification and reservoir characterization. Tulsa, OK, USA: Society of Exploration Geophysicists, 2007. – 464 с. DOI: 10.1190/1.9781560801900.

7. Das G., Chattopadhyay M., Gupta S. A comparison of self-organising maps and principal components analysis. *International // Journal of Market Research*. – 2016. – Vol. 58. No. 6. – pp. 815–834. DOI: 10.2501/ijmr-2016-039.
8. Interpretation of three-dimensional seismic data / Ed. A.R. Brown. – 2011. – Vol. 42. DOI: 10.1306/M4271346.
9. Kaz'min V.G., Verzhbitskii E.V. Age and origin of the South Caspian Basin // *Oceanology*. – 2011. – Vol. 51. Issue 1. – pp. 131–140. DOI: 10.1134/s0001437011010073.
10. Kazemeini S.H., Juhlin C., Zinck-Jorgensen K., Norden B. Application of the continuous wavelet transform on seismic data for mapping of channel deposits and gas detection at the CO2SINK site, Ketzin, Germany // *Geophysical Prospecting*. – 2008. – Vol. 57. No. 1. – pp. 111–123. DOI: 10.1111/j.1365-2478.2008.00723.x.
11. Kourki M., Riahi M.A. Seismic facies analysis from pre-stack data using self-organizing maps // *Journal of Geophysics and Engineering*. – 2014. – Vol. 11. No. 6. – Art. No. 065005. DOI: 10.1088/1742-2132/11/6/065005.
12. Malikov R., Babayev G. Applying spectral decomposition to seismic facies clustering with unsupervised machine learning // *Geofizicheskiy Zhurnal*. – 2025. – Vol. 47. Issue 3. DOI: 10.24028/gj.v47i3.320290.
13. Nanda N.C. Seismic data interpretation and evaluation for hydrocarbon exploration and production. In: *Advances in oil and gas exploration and production*. Switzerland: Springer Cham, 2021. – 304 p. DOI: 10.1007/978-3-030-75301-6.
14. Owusu P., Raef A., Sharaf E. Carbonate seismic facies analysis in reservoir characterization: a machine learning approach with integration of reservoir mineralogy and porosity // *Geosciences*. – 2025. – Vol. 15. No. 7. – Art. No. 257. DOI: 10.3390/geosciences15070257.
15. Partyka G., Gridley J., Lopez J. Interpretational applications of spectral decomposition in reservoir characterization // *The Leading Edge*. – 1999. – Vol. 18. No. 3. – pp. 353–360. DOI: 10.1190/1.1438295.
16. Posamentier H.W., Kolla V. Seismic geomorphology and stratigraphy of depositional elements in Deep-Water settings // *Journal of Sedimentary Research*. – 2003. – Vol. 73. No. 3. – pp. 367–388. DOI: 10.1306/111302730367.
17. Roden R., Smith T., Sacrey D. Geologic pattern recognition from seismic attributes: Principal component analysis and self-organizing maps // *Interpretation*. – 2015. – Vol. 3. No. 4. SAE59–SAE83. DOI: 10.1190/int-2015-0037.1.
18. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead // *Nature Machine Intelligence*. – 2019. – Vol. 1. No. 5. – pp. 206–215. DOI: 10.1038/s42256-019-0048-x.
19. Samakinde C.A., Van Bever Donker J.M., Durrheim R., Manzi M. Application of seismic stratigraphy in reservoir characterisation: a case study of the passive margin deposits of the northern Orange Basin, South Africa // *Journal of Petroleum Exploration and Production Technology*. – 2020. – Vol. 11. No. 1. – pp. 45–61. DOI: 10.1007/s13202-020-01050-9.
20. Samuel S.A., Knapp C.C., Knapp J.H. Seismic facies classification of salt structures and sediments in the Northern gulf of Mexico using self-organizing maps // *Geosciences*. – 2025. – Vol. 15. No. 5. – Art. No. 183. DOI: 10.3390/geosciences15050183.
21. Sinha S., Routh P.S., Anno P.D., Castagna J.P. Spectral decomposition of seismic data with continuous-wavelet transform // *Geophysics*. – 2005. – Vol. 70. No. 6. – pp. 19–25. DOI: 10.1190/1.2127113.
22. Smith-Rouch L.S. Oligocene–Miocene Maykop/Diatom Total Petroleum System of the South Caspian Basin Province, Azerbaijan, Iran, and Turkmenistan // *Bulletin*. – 2006. – No. 2201. Chapter I. – 27 p. DOI: 10.3133/b2201i.
23. Sukmono S., Machado V., Adelina R., Ambarsari D. Integration of 3D seismic attributes for preliminary shallow geohazard identification in deep water exploration area with no well data // *First Break*. – 2017. – Vol. 35. No. 8. DOI: 10.3997/1365-2397.35.8.89810.
24. Von Hartmann H., Buness H., Krawczyk C.M., Schulz R. 3-D seismic analysis of a carbonate platform in the Molasse Basin – reef distribution and internal separation with seismic attributes // *Tectonophysics*. – 2012. – Vol. 572–573. – pp. 16–25. DOI: 10.1016/j.tecto.2012.06.033.

25. Wang Y. Frequencies of the Ricker wavelet // *Geophysics*. – 2015. – Vol. 80. No. 2. – pp. A31–A37. DOI: 10.1190/geo2014-0441.1.
26. Yetirmishli G. J., Kazimova S. E., Samedzade A. V. Integrated application of geophysical methods in the South Caspian basin (based on the Bulla-Deniz oil and gas field) // *Geology and Geophysics of Russian South*. – 2025. – Vol. 15. No. 2. – pp. 142–154. DOI: 10.46698/VNC.2025.35.96.001.
27. Yilmaz O. Seismic data analysis. In: *Processing, Inversion, and Interpretation of Seismic Data*. Tulsa, OK, USA: Society of Exploration Geophysicists, 2001. – 1028 p. DOI: 10.1190/1.9781560801580.
28. Zhao T., Jayaram V., Roy A., Marfurt K.J. A comparison of classification techniques for seismic facies recognition // *Interpretation*. – 2015. – Vol. 3. No. 4. – pp. SAE29–SAE58. DOI: 10.1190/int-2015-0044.1.
29. Zhu Z., Chen X., Ren H., Tao L., Jiang J., Wang T., Cheng M., Ding S., Du R. Seismic facies analysis using the multiattribute SOM-K-Means clustering // *Computational Intelligence and Neuroscience*. – 2022. – pp. 1–11. DOI: 10.1155/2022/1688233.

References

1. Nikulin I.I., Samsonov A.A. Neural network cluster analysis of areal geophysical data of the Khibiny-Lovozero volcano-plutonic ore-bearing complex (Kola peninsula) by self-organizing maps of Kohonen method. *Geophysical Research*. 2021. Vol. 22. No. 1. pp. 25–39. DOI: 10.21455/gr2021.1-2. (In Russ.)
2. Potekhin D.V., Galkin S.V. Use of machine learning technology to model the distribution of lithotypes in the Permo-Carboniferous oil deposit of the Usinskoye field. *Journal of Mining Institute*. 2023. Vol. 259. pp. 41–51. DOI: 10.31897/PMI.2022.101. (In Russ.)
3. Priezzhev I.I., Vasilev M.A., Petrenko E.N. Construction of predictive maps of effective gas-saturated thicknesses using seismic waveform based on Kohonen neural networks. *Journal of Geophysics*. 2020. No. 6. pp. 49–53. (In Russ.)
4. Ezirbaev T.B. The Lower Cretaceous reservoir of the Starogroznenkoye oil and gas field as an object of geological modeling. *Geology and Geophysics of Russian South*. 2025. Vol. 15. No. 3. pp. 239–254. DOI: 10.46698/VNC.2025.27.39.001. (In Russ.)
5. Castagna J.P., Sun S., Siegfried R.W. Instantaneous spectral analysis: Detection of low-frequency shadows associated with hydrocarbons. *The Leading Edge*. 2003. Vol. 22. No. 2. pp. 120–127. DOI: 10.1190/1.1559038.
6. Chopra S., Marfurt K.J. Seismic attributes for prospect identification and reservoir characterization. Tulsa, OK, USA. Society of Exploration Geophysicists. 2007. 464 c. DOI: 10.1190/1.9781560801900.
7. Das G., Chattopadhyay M., Gupta S. A comparison of self-organising maps and principal components analysis. *International Journal of Market Research*. 2016. Vol. 58. No. 6. pp. 815–834. DOI: 10.2501/ijmr-2016-039.
8. *Interpretation of three-dimensional seismic data*. Ed. A.R. Brown. 2011. Vol. 42. DOI: 10.1306/M4271346.
9. Kaz'min V.G., Verzhbitskii E.V. Age and origin of the South Caspian Basin. *Oceanology*. 2011. Vol. 51. Issue 1. pp. 131–140. DOI: 10.1134/s0001437011010073.
10. Kazemeini S.H., Juhlin C., Zinck-Jorgensen K., Norden B. Application of the continuous wavelet transform on seismic data for mapping of channel deposits and gas detection at the CO2SINK site, Ketzin, Germany. *Geophysical Prospecting*. 2008. Vol. 57. No. 1. pp. 111–123. DOI: 10.1111/j.1365-2478.2008.00723.x.
11. Kourki M., Riahi M.A. Seismic facies analysis from pre-stack data using self-organizing maps. *Journal of Geophysics and Engineering*. 2014. Vol. 11. No. 6. Art. No. 065005. DOI: 10.1088/1742-2132/11/6/065005.
12. Malikov R., Babayev G. Applying spectral decomposition to seismic facies clustering with unsupervised machine learning. *Geofizicheskiy Zhurnal*. 2025. Vol. 47. Issue 3. DOI: 10.24028/gj.v47i3.320290.

13. Nanda N.C. Seismic data interpretation and evaluation for hydrocarbon exploration and production. In: *Advances in oil and gas exploration and production*. Switzerland. Springer Cham. 2021. 304 p. DOI: 10.1007/978-3-030-75301-6.
14. Owusu P., Raef A., Sharaf E. Carbonate seismic facies analysis in reservoir characterization: a machine learning approach with integration of reservoir mineralogy and porosity. *Geosciences*. 2025. – Vol. 15. No. 7. Art. No. 257. DOI: 10.3390/geosciences15070257.
15. Partyka G., Gridley J., Lopez J. Interpretational applications of spectral decomposition in reservoir characterization. *The Leading Edge*. 1999. Vol. 18. No. 3. pp. 353–360. DOI: 10.1190/1.1438295.
16. Posamentier H.W., Kolla V. Seismic geomorphology and stratigraphy of depositional elements in Deep-Water settings. *Journal of Sedimentary Research*. 2003. Vol. 73. No. 3. pp. 367–388. DOI: 10.1306/111302730367.
17. Roden R., Smith T., Sacrey D. Geologic pattern recognition from seismic attributes: Principal component analysis and self-organizing maps. *Interpretation*. 2015. Vol. 3. No. 4. SAE59–SAE83. DOI: 10.1190/int-2015-0037.1.
18. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*. 2019. Vol. 1. No. 5. pp. 206–215. DOI: 10.1038/s42256-019-0048-x.
19. Samakinde C.A., Van Bever Donker J.M., Durrheim R., Manzi M. Application of seismic stratigraphy in reservoir characterisation: a case study of the passive margin deposits of the northern Orange Basin, South Africa. *Journal of Petroleum Exploration and Production Technology*. 2020. Vol. 11. No. 1. pp. 45–61. DOI: 10.1007/s13202-020-01050-9.
20. Samuel S.A., Knapp C.C., Knapp J.H. Seismic facies classification of salt structures and sediments in the Northern gulf of Mexico using self-organizing maps. *Geosciences*. 2025. Vol. 15. No. 5. Art. No. 183. DOI: 10.3390/geosciences15050183.
21. Sinha S., Routh P.S., Anno P.D., Castagna J.P. Spectral decomposition of seismic data with continuous-wavelet transform. *Geophysics*. 2005. Vol. 70. No. 6. pp. 19–25. DOI: 10.1190/1.2127113.
22. Smith-Rouch L.S. Oligocene–Miocene Maykop/Diatom Total Petroleum System of the South Caspian Basin Province, Azerbaijan, Iran, and Turkmenistan. *Bulletin*. 2006. No. 2201. Chapter I. 27 p. DOI: 10.3133/b2201i.
23. Sukmono S., Machado V., Adelina R., Ambarsari D. Integration of 3D seismic attributes for preliminary shallow geohazard identification in deep water exploration area with no well data. *First Break*. 2017. Vol. 35. No. 8. DOI: 10.3997/1365-2397.35.8.89810.
24. Von Hartmann H., Buness H., Krawczyk C.M., Schulz R. 3-D seismic analysis of a carbonate platform in the Molasse Basin – reef distribution and internal separation with seismic attributes. *Tectonophysics*. 2012. Vol. 572–573. pp. 16–25. DOI: 10.1016/j.tecto.2012.06.033.
25. Wang Y. Frequencies of the Ricker wavelet. *Geophysics*. 2015. Vol. 80. No. 2. pp. A31–A37. DOI: 10.1190/geo2014-0441.1.
26. Yetirmishli G. J., Kazimova S. E., Samedzade A. V. Integrated application of geophysical methods in the South Caspian basin (based on the Bulla-Deniz oil and gas field). *Geology and Geophysics of Russian South*. 2025. Vol. 15. No. 2. pp. 142–154. DOI: 10.46698/VNC.2025.35.96.001.
27. Yilmaz O. Seismic data analysis. In: *Processing, Inversion, and Interpretation of Seismic Data*. Tulsa, OK, USA. Society of Exploration Geophysicists. 2001. 1028 p. DOI: 10.1190/1.9781560801580.
28. Zhao T., Jayaram V., Roy A., Marfurt K.J. A comparison of classification techniques for seismic facies recognition. *Interpretation*. 2015. Vol. 3. No. 4. pp. SAE29–SAE58. DOI: 10.1190/int-2015-0044.1.
29. Zhu Z., Chen X., Ren H., Tao L., Jiang J., Wang T., Cheng M., Ding S., Du R. Seismic facies analysis using the multiattribute SOM-K-Means clustering. *Computational Intelligence and Neuroscience*. 2022. pp. 1–11. DOI: 10.1155/2022/1688233.