

РУБРИКА: ГЕОЛОГИЯ И ГЕОЛОГО-РАЗВЕДОЧНЫЕ РАБОТЫ

### **Построение модели трещиноватости карбонатного пласта: опыт применения машинного обучения на газовом месторождении Узбекистана**

Ш. Э. Тогаев (ООО Surhan Gas Chemical Operating Company),  
А. В. Гаврилов (ООО Surhan Gas Chemical Operating Company),  
А. Г. Клевицкий (ООО Surhan Gas Chemical Operating Company)

Представлен комплексный подход к построению модели сети дискретных трещин (DFN) карбонатного пласта газового месторождения Республики Узбекистан с применением методов машинного обучения на двух ключевых этапах моделирования. Продуктивный пласт месторождения сложен низкопористыми доломитизированными известняками юрского возраста с интенсивной естественной трещиноватостью, обусловленной деформацией надвиговой структуры. Разработана концепция развития трещиноватости, связывающая пространственное распределение и ориентацию трещин со структурно-тектонической обстановкой: осями складчатости, зонами максимальной кривизны пластов и стадиями формирования дизъюнктивных нарушений. Для прогнозирования интенсивности трещиноватости в скважинах, не охваченных электрическим микросканированием (ЭМС), составляющих около 70 % фонда, построена искусственная нейронная сеть (ИНС), обученная на данных 7 скважин с ЭМС и базовом комплексе методов геофизических исследований скважин (ГИС). Определена оптимальная архитектура сети, обеспечившая коэффициент детерминации  $R^2 = 0,90$  на тестовой выборке; кросс-валидация с последовательным исключением одной скважины показала  $R^2 \approx 0,7$ , подтвердив обобщающую способность модели. Пространственный тренд интенсивности трещиноватости сформирован на основе куба «повторяемости» трещиноватых фаций, построенного двухэтапной схемой машинного обучения: классификацией литотипов по данным ГИС методом многоуровневой графовой кластеризации и последующей классификацией сейсмических атрибутов алгоритмом демократической ассоциации нейронных сетей (DNNA — Democratic Neural Network Association), в комбинации с геометрическими и структурными драйверами. На основе DFN-модели построена гидродинамическая модель двойной пористости, адаптация которой на данные межскважинного гидропрослушивания позволила уточнить параметры трещинной среды.

**Ключевые слова:** естественная трещиноватость, модель сети дискретных трещин (DFN), искусственные нейронные сети, машинное обучение, электрическое микросканирование, карбонатный коллектор, двойная пористость.

## Discrete Fracture Network Modeling of a Carbonate Reservoir: A Machine Learning Case Study from a Gas Field in Uzbekistan

S. E. Togaev (LLC “Surhan Gas Chemical Operating Company”),  
A. V. Gavrilov (LLC “Surhan Gas Chemical Operating Company”),  
A. G. Klevitskiy (LLC “Surhan Gas Chemical Operating Company”)

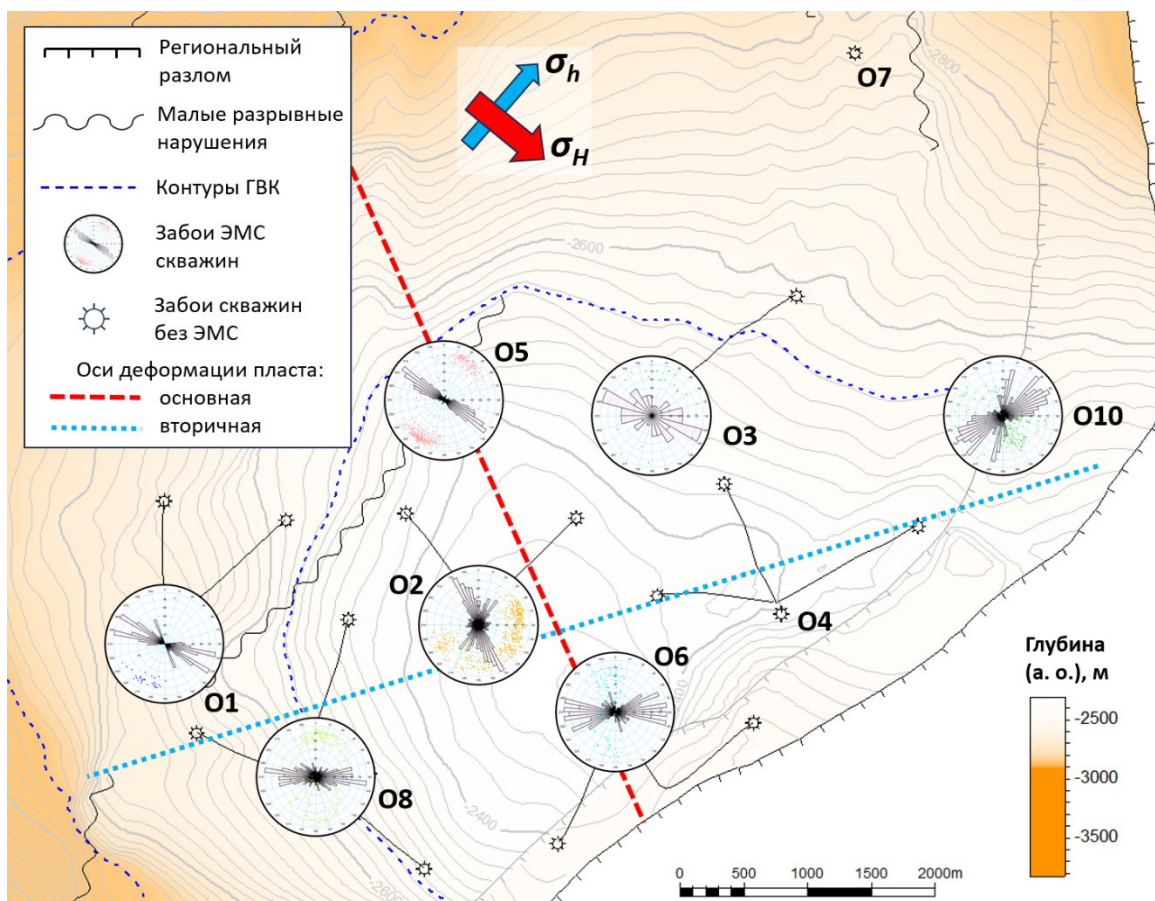
A comprehensive approach to discrete fracture network (DFN) modeling of a carbonate reservoir at a gas field in the Republic of Uzbekistan is presented, with machine learning methods applied at two key stages of the modeling workflow. The productive formation consists of low-porosity dolomitized Jurassic limestones with intense natural fracturing caused by deformation of a thrust structure. A fracture development concept has been established that links the spatial distribution and orientation of fractures to the structural-tectonic setting: fold axes, zones of maximum formation curvature, and stages of disjunctive fault development. To predict fracture intensity in wells lacking electrical micro-imaging (EMI) surveys, which constitute approximately 70 % of the well stock, an artificial neural network (ANN) was trained on data from 7 wells that had both EMI surveys and a standard suite of well logging methods. An optimal network architecture was identified, yielding a coefficient of determination  $R^2 = 0.90$  on the test dataset; leave-one-well-out cross-validation yielded  $R^2 \approx 0.7$ , confirming the model's generalization capability. The spatial trend of fracture intensity was constructed using a repeatability cube of fractured facies, built via a two-stage machine learning approach: well log-based lithotype classification using multi-resolution graph-based clustering, followed by seismic attribute classification using the Democratic Neural Network Association (DNNA) algorithm, combined with geometric and structural drivers. A dual-porosity simulation model was built on the basis of the DFN model, and its history matching against interwell interference test data enabled calibration of the fracture medium parameters.

**Keywords:** naturally fractured reservoir, discrete fracture network (DFN), artificial neural networks, machine learning; electrical micro-imaging, carbonate reservoir, dual porosity.

## Введение

Рассматриваемое газовое месторождение расположено в северной части Афгано-Таджикского нефтегазоносного бассейна, на территории Республики Узбекистан. Продуктивные горизонты месторождения приурочены к юрской секции надвиговой структуры. Основной продуктивный пласт сложен низкопористыми известняками, претерпевшими вторичные изменения: интенсивное растрескивание в результате деформации пласта и доломитизацию. Коллекторские свойства пород пласта имеют двойственную природу: проницаемость системы естественных трещин на несколько порядков превосходит проницаемость поровой матрицы, тогда как основная емкость коллектора сосредоточена в матрице [1]. Поэтому моделирование пространственного распределения трещиноватости пласта — необходимое условие обоснования местоположений и способов заканчивания эксплуатационных скважин при проектировании системы разработки месторождения. При этом статическому и последующему гидродинамическому моделированию должно предшествовать формирование концепции развития трещиноватости.

Основным источником количественной информации о параметрах трещиноватости являются данные электрического микросканирования (ЭМС) — специального метода геофизических исследований (ГИС) в открытом стволе скважины, вскрывшей исследуемый пласт. На рассматриваемом месторождении расширенным комплексом методов ГИС, включающим ЭМС, охвачена только первая (вертикальная) скважина на каждом кусте — около 30 % фонда, тогда как остальные скважины на кустах (наклонно-направленные) охарактеризованы только базовым набором методов ГИС (рис. 1).



**Рисунок 1.** Расположение осей деформации и фонда современных скважин на карте кровли моделируемого пласта

Инструментом интеграции всех данных по трещиноватости пласта послужила модель сети дискретных трещин — DFN (Discrete Fracture Network), в которой каждая трещина представляется в виде явной пространственной плоскости с геометрическими размерами, раскрытостью и пространственным положением в объеме пласта. По сравнению с непрерывным моделированием CFM (Continuous Fracture Modeling), DFN-подход обеспечивает наглядное воспроизведение сети трещин, прямой учет связности трещин и анизотропии фильтрационных свойств, а также возможность отслеживания влияния отдельных геометрических параметров трещин на распределение компонентов тензора проницаемостей в гидродинамической модели двойной среды.

В данной работе представлен комплексный подход к построению DFN-модели с широким применением методов машинного обучения на двух ключевых этапах: прогнозирование интенсивности трещиноватости в скважинах без ЭМС с помощью искусственных нейронных сетей (ИНС) и построение пространственного тренда интенсивности трещиноватости в межскважинном пространстве с использованием классификации сейсмических данных алгоритмом DNN (Democratic Neural Network Association) [2].

## Методология

Процесс построения DFN-модели включает два последовательных этапа. На первом этапе формируются непрерывные кубы пространственных параметров трещиноватости — тренды интенсивности, углов падения и азимутов — на основе концепции развития трещиноватости, скважинных данных, включая синтетические кривые ИНС для ~70 % скважин без ЭМС, и сейсмических атрибутов. На втором этапе стохастический симулятор генерирует ансамбль реализаций дискретных трещин, каждая из которых представляет собой явную пространственную плоскость с индивидуальными геометрическими параметрами. При этом скважинные данные (ЭМС и синтетические прогнозы ИНС) жестко воспроизводятся в точках скважин, а пространственные тренды задают вероятностные ограничения в межскважинном пространстве.

## Концепция развития трещиноватости

Концепция развития трещиноватости служит основой всего процесса DFN-моделирования, определяя закономерности формирования трещин, их пространственного распределения и ориентации. На рассматриваемом месторождении концепция разработана на основе комплексного анализа структурно-тектонической обстановки, результатов интерпретации массива данных ЭМС и трехмерной сейсморазведки.

Исследуемый пласт относится к надвиговой области подсолевой карбонатной толщи юрских отложений. Формирование трещин связано с деформационными процессами, обусловленными тектонической коллизией. В зависимости от степени нагружения и деформации пластов различают несколько стадий формирования внутренней структуры разломной зоны: ранняя дизъюнктивная стадия предполагает небольшие деформации с образованием обширных зон трещиноватости, тогда как поздняя стадия характеризуется большими смещениями и формированием разломов с ограниченной прилегающей зоной трещиноватости.

Концепция базируется на представлении о наличии складки с двумя осями — основной и второстепенной (рис. 1), к которым приурочены максимальные интенсивности трещиноватости [3]. Области наибольшего количества трещин связаны с ранней стадией дизъюнктивных нарушений и приурочены к зонам максимальной кривизны пластов, тогда как вблизи крупных разломов (поздняя стадия) трещиноватость ограничена. Направление простирания трещин соответствует простиранию осей основных и локальных складок.

## Прогнозирование интенсивности трещиноватости в скважинах без ЭМС

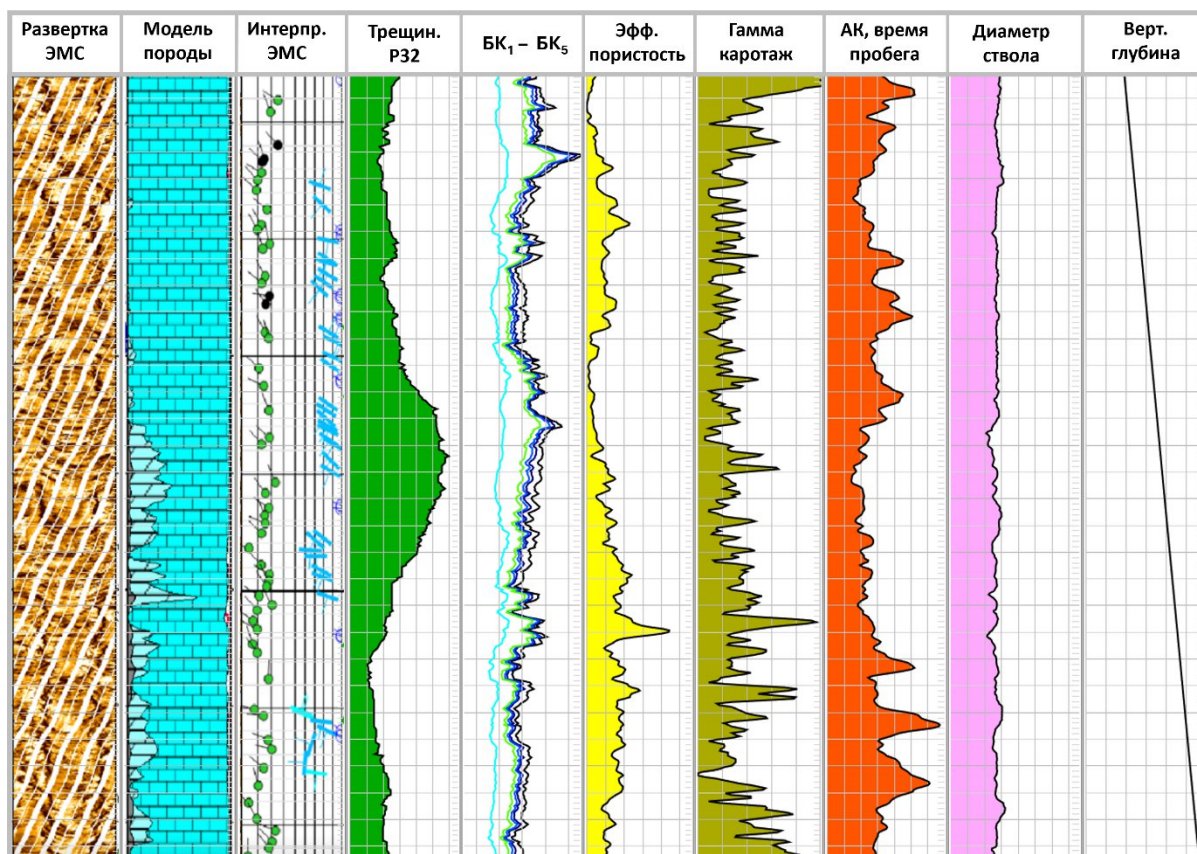
Интенсивность трещиноватости  $R_{32}$  — суммарная площадь трещин в единице объема породы ( $\text{м}^2/\text{м}^3$ ) — является базовой количественной характеристикой трещиноватости коллектора. Прогнозирование интенсивности по данным базового комплекса ГИС позволяет расширить набор скважинных точек, используемых при пространственном моделировании, с 7 скважин с ЭМС до полного фонда, что обеспечивает дополнительные точки контроля интенсивности в межскважинном пространстве. Прочие параметры трещин — азимуты и углы падения, раскрытость и геометрические размеры — распределяются в пространстве на основе данных ЭМС, гидродинамических исследований скважин (ГДИС) и принятой концепции развития трещиноватости.

Интенсивность трещиноватости является гетероскедастичным по своей природе свойством [4], характеризующимся непостоянством дисперсии в пространстве: в одних зонах пласта трещины распространены относительно равномерно, тогда как в других наблюдаются резкие скачки от нуля до высоких значений. Поэтому каждая дополнительная скважина, предоставляющая независимые от пространственных трендов данные об интенсивности трещиноватости, критически важна для повышения достоверности DFN-модели.

Первичный корреляционно-регрессионный анализ показал отсутствие значимых линейных связей между интенсивностью по ЭМС и показателями стандартных методов ГИС: коэффициенты парной детерминации не превысили  $R^2 \approx 0,6$ , что не позволило использовать парные корреляции для прямого прогнозирования интенсивности трещиноватости. Поэтому для решения задачи была использована искусственная нейронная сеть — вычислительная модель, способная устанавливать сложные нелинейные зависимости между многомерными входными данными [5]. Связь параметров ГИС с трещиноватостью носит характер гладкой нелинейной функции нескольких переменных; ИНС аппроксимируют именно такие зависимости, тогда как методы на основе деревьев решений (Random Forest, XGBoost) строят кусочно-постоянную аппроксимацию, менее подходящую для описания непрерывных физических процессов. Кроме того, при применении модели на скважинах без ЭМС возможны комбинации входных параметров, выходящие за пределы обучающей выборки; ИНС за счет гладких функций активации способна к экстраполяции, тогда как модели на основе деревьев решений за границей обучающих данных возвращают константу ближайшего листа. Вместе с тем сопоставление с альтернативными алгоритмами представляет интерес при расширении фонда скважин с ЭМС.

## Сбор и подготовка данных

Интерпретация данных ЭМС позволяет получить информацию о типах трещин (проницаемые, непроницаемые), раскрытости, углах падения и простирания. В скважинах без ЭМС доступны методы стандартного комплекса ГИС — гамма-каротаж (ГК), акустический каротаж (АК), боковой каротаж различной глубинности (БК<sub>1</sub> — БК<sub>5</sub>), профилометрия (ПМ), а также результат интерпретации — эффективная пористость (ПОР) и вертикальная глубина TVD (рис. 2).



**Рисунок 2.** Схематичный планшет скважины с методами ГИС, использовавшимися для моделирования трещиноватости: интерпретация ЭМС и набор базовых методов ГИС

Для построения модели использованы данные 7 скважин с ЭМС. Целевым параметром для обучения ИНС служила интенсивность трещиноватости (R32), полученная интерпретацией ЭМС в этих скважинах. Общий размер массива составил более 19 тысяч точек. Перед подачей на вход ИНС выполнена предобработка входных параметров с учетом характера их распределений. Кривые бокового каротажа (БК<sub>1</sub> — БК<sub>5</sub>), характеризующиеся резко асимметричным распределением с диапазоном значений в несколько порядков (табл. 1), были предварительно логарифмированы для приведения к более симметричной форме распределения. Затем все входные параметры, включая логарифмированные значения БК, нормированы в диапазон [0, 1] методом

минимакс-нормализации. Остальные параметры (ГК, АК, ПОР, ПМ, TVD) не требовали логарифмирования и нормированы в диапазон [0, 1] напрямую. Подготовленные данные разделены на обучающую (75 %) и тестовую (25 %) выборки.

**Таблица 1.** Статистические показатели петрофизических данных и интенсивности трещиноватости по данным ЭМС для объединенного массива данных 7 скважин

Показатель	TVD (м)	БК <sub>1</sub> (Ом·м)	БК <sub>2</sub> (Ом·м)	БК <sub>3</sub> (Ом·м)	БК <sub>4</sub> (Ом·м)	БК <sub>5</sub> (Ом·м)	ГК (API)	ПОР (д. ед.)	АК (мкс/фт)	ПМ (%)	Р32 (м <sup>2</sup> /м <sup>3</sup> )
Мин.	3063	2,1	2,3	2,4	2,5	3,2	2	0,00	45,5	-26,32	0,00
Макс.	3925	3908	100000	87758	667154	667455	30	0,16	208,4	39,77	16,10
Среднее	3483	103	274	659	1482	1723	4,4	0,02	82,5	0,47	1,93
Медиана	3487	46	127	165	198	242	3,2	0,02	50,3	0,72	0,63
Ст. откл.	190	163	1047	2859	6512	7163	3,7	0,016	51,6	1,41	2,97


Эффективная пористость является результатом петрофизической интерпретации и, строго говоря, не представляет независимого замера. На раннем этапе настоящего исследования зависимость «пористость — интенсивность трещиноватости» послужила отправной точкой для построения модели прогнозирования, поэтому изначально пористость была включена в набор входных признаков ИНС. Полученное качество прогноза ( $R^2 = 0,90$  на тестовой выборке) не давало оснований для пересмотра набора признаков. Тем не менее для проверки был проведен контрольный эксперимент: модель обучена на идентичном наборе данных с исключением пористости из входных признаков. Результат не показал улучшения качества прогноза, поэтому пористость была сохранена в составе входных параметров в текущей реализации модели ИНС.

Трещиноватость оказывает существенное влияние на физические свойства карбонатного коллектора: проницаемые трещины изменяют электрическое сопротивление среды, увеличивают время пробега упругих волн и вызывают их затухание, а также провоцируют кавернообразование в стволе скважины. Кроме того, трещины зачастую содержат осадок от фильтрации пластовых вод, что изменяет отклик гамма-каротажа в интервалах повышенной трещиноватости. Поэтому методы базового комплекса ГИС — боковой каротаж различной глубинности, акустический каротаж, гамма-каротаж, профилометрия — неизбежно несут в себе отклик на присутствие трещин в исследуемом интервале. Однако характер этого отклика в значительной мере маскируется влиянием литологии, пористости матрицы и условий вскрытия, чем отчасти объясняется отсутствие значимых парных корреляций, отмеченное выше. Применение ИНС позволяет выявить скрытые нелинейные комбинации входных параметров, которые в совокупности несут информацию о трещиноватости, недоступную при анализе каждого параметра в отдельности.

## Построение модели прогнозирования интенсивности трещиноватости

Программная реализация ИНС выполнена на языке Python с использованием библиотек NumPy, scikit-learn, TensorFlow и Keras, обеспечивающих гибкость настройки архитектуры сети, параметров обучения и воспроизводимость результатов вычислений.


Обучение сети выполнялось методом градиентного спуска с алгоритмом обратного распространения ошибки. Оптимизация архитектуры производилась экспериментальным подбором: варьировались число скрытых слоев (1–3), функции активации (ReLU в промежуточных слоях и сигмоида в последнем скрытом слое для предотвращения «паралича» нейронов) и число нейронов (от 1 до 150 на слой). Эксперименты показали, что независимо от числа нейронов однослойная сеть не позволяет достичь коэффициента детерминации  $R^2$  выше 0,6. Для двух- и трехслойных конфигураций оптимальными по соотношению точности и компактности оказались следующие количества нейронов: 2 скрытых слоя — 42 и 10 нейронов; 3 скрытых слоя — 21, 11 и 11 нейронов (рис. 3). Более глубокие ИНС обеспечили меньшее суммарное число нейронов при более высокой прогнозной способности.



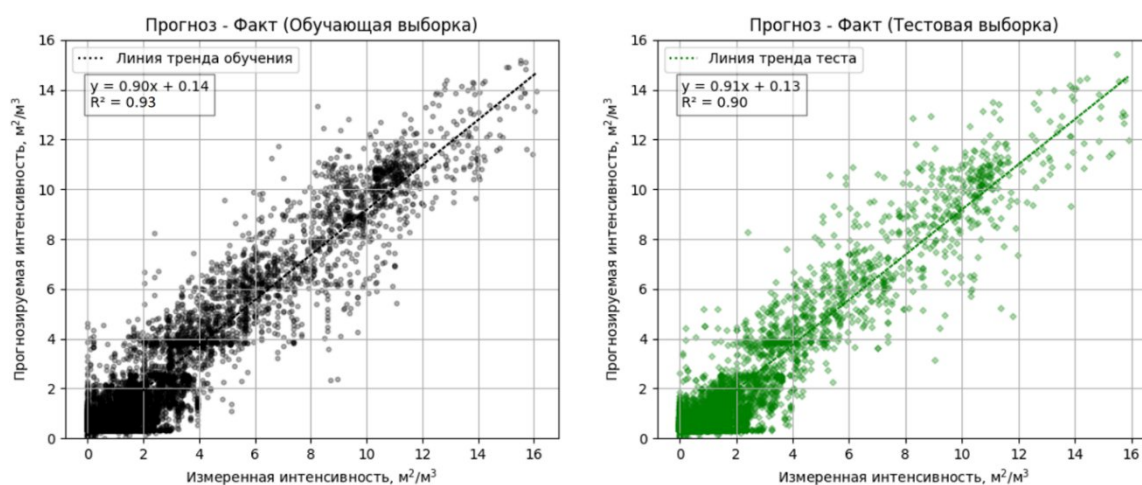
**Рисунок 3.** Пример использованной в работе архитектуры ИНС с тремя скрытыми слоями

Скорость обучения (learning rate) — безразмерный коэффициент, от которого зависит устойчивость сходимости градиентного спуска. Значения этого коэффициента, подобранные по динамике функции потерь (рис. 4), составили 0,04 для двухслойной конфигурации и 0,02 — для трехслойной. По мере обучения скорость снижения ошибки падает: если в начале для уменьшения ошибки на 1 % достаточно ~100 эпох, то ближе к концу требуется более 1000. Увеличение числа итераций позволило достичь коэффициентов детерминации  $R^2 = 0,93$  на обучающей и

$R^2 = 0,90$  на тестовой выборках (рис. 5), что подтверждает обобщающую способность модели и отсутствие переобучения.



**Рисунок 4.** Динамика функции потерь по эпохам для различных скоростей обучения ( $V_0$ ) и конфигураций ИНС

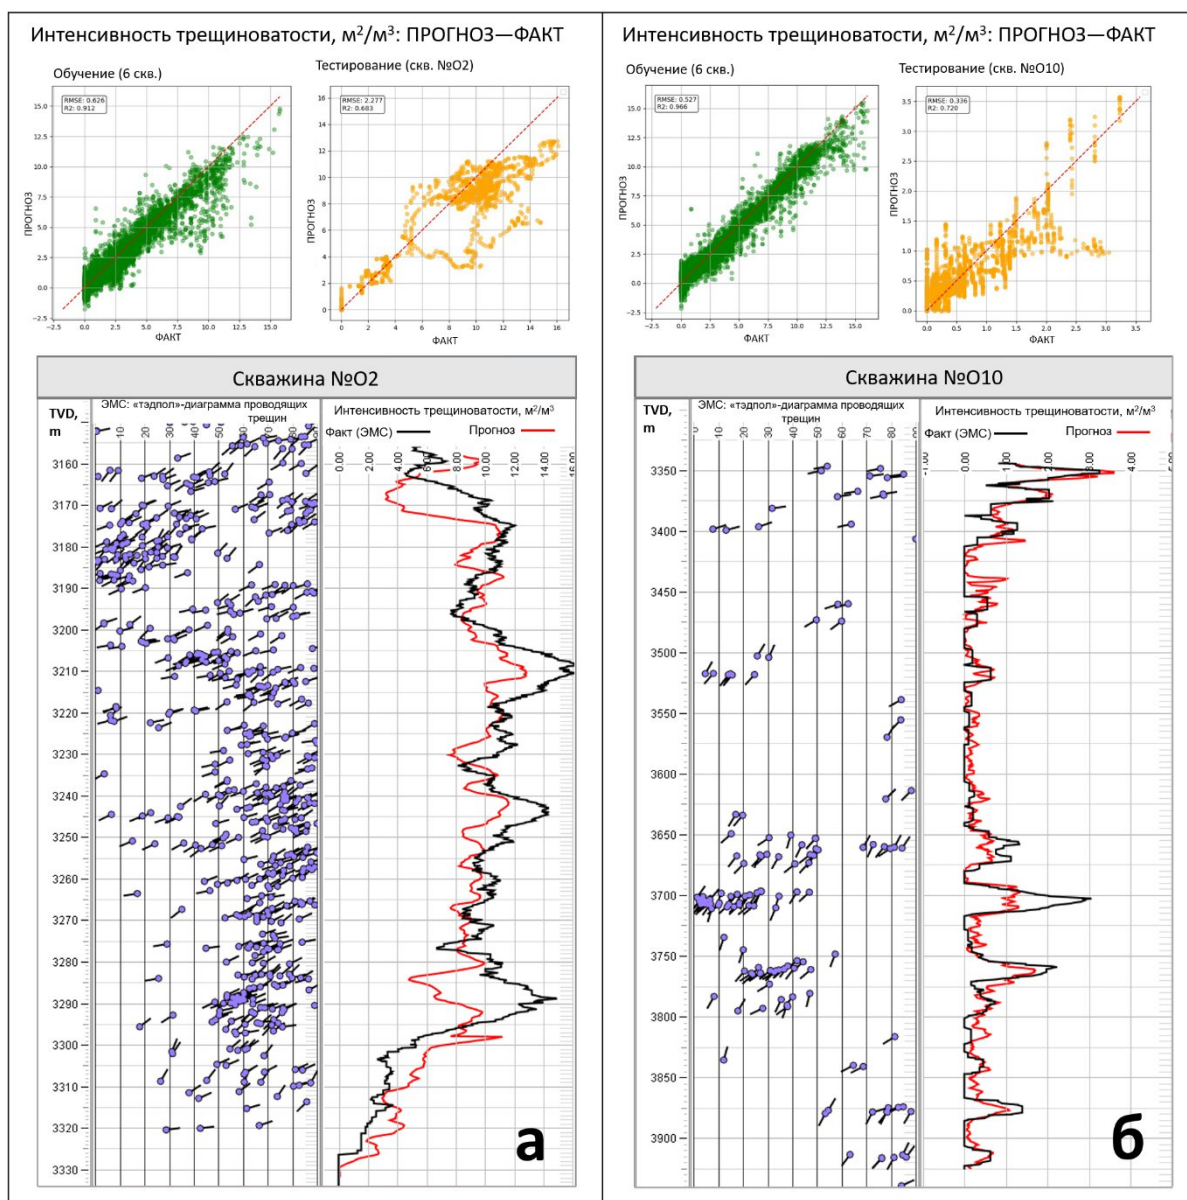


**Рисунок 5.** Сопоставление прогнозируемой и измеренной интенсивностей трещиноватости для обучающей (слева) и тестовой (справа) выборки

### Кросс-валидация модели ИНС

Для оценки обобщающей способности модели проведена кросс-валидация по скважинам: в каждом из 7 экспериментов модель обучалась на данных шести скважин, а седьмая использовалась для независимого тестирования. Данная схема воспроизводит реальные условия применения модели на скважинах без ЭМС. На рисунке 6

приведены результаты для скважин № О2 (рис. 6а) и № О10 (рис. 6б): прогнозируемые значения  $R_{32}$  воспроизводят основные интервалы повышенной трещиноватости, зафиксированные ЭМС, — с коэффициентами детерминации  $R^2 = 0,68$  и  $R^2 = 0,72$  соответственно. Снижение  $R^2$  относительно базовой модели (0,90) объясняется тем, что при исключении скважины из обучения модель лишается информации о локальных особенностях разреза в данной точке месторождения. Аналогичные результаты получены для остальных пяти скважин.



**Рисунок 6.** Кросс-валидация модели ИНС: проведено обучение модели на 6 скважинах с проверкой прогнозной способности на 7-й скважине: а) проверочная скважина № О2, б) скважина № О10

При появлении новой скважины с ЭМС модель ИНС подлежит полному переобучению на расширенном наборе данных. Архитектура сети может быть сохранена при незначительном пополнении обучающей выборки;

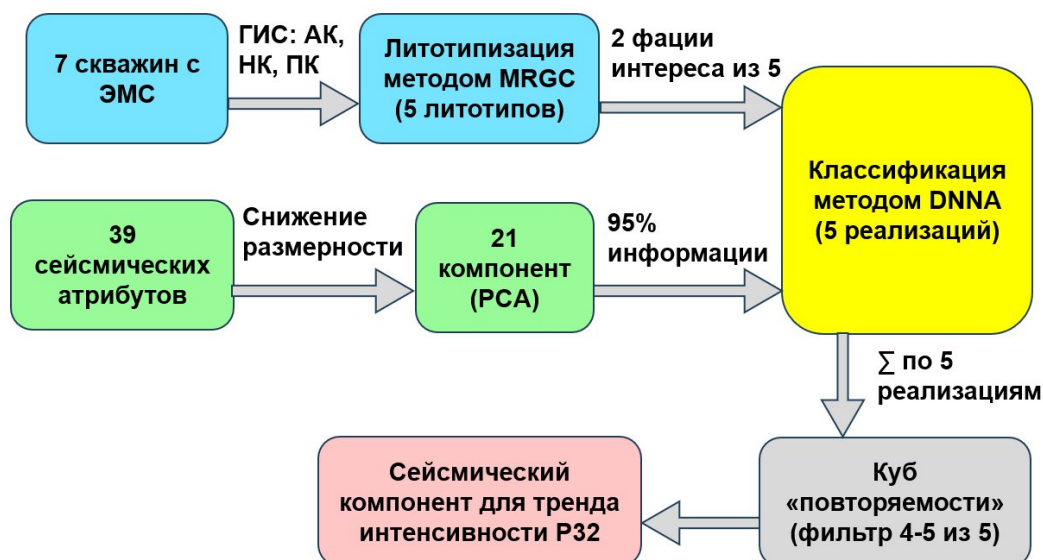
однако оптимальность выбранной конфигурации при увеличении объема данных не гарантируется и должна быть проверена повторной процедурой подбора гиперпараметров: числа скрытых слоев, числа нейронов, скорости обучения и функций активации.

## **Пространственное распределение параметров трещиноватости**

### ***Интенсивность трещиноватости***

Интенсивность трещиноватости  $R_{32}$  характеризуется выраженной гетероскедастичной пространственной изменчивостью [4], что ограничивает применимость стационарных геостатистических методов на основе только скважинных данных и требует привлечения внешних пространственных трендов. Для построения тренда  $R_{32}$  в объеме модели использована линейная комбинация геометрических, структурных и сейсмических драйверов, отражающих физическую природу формирования трещинного коллектора.

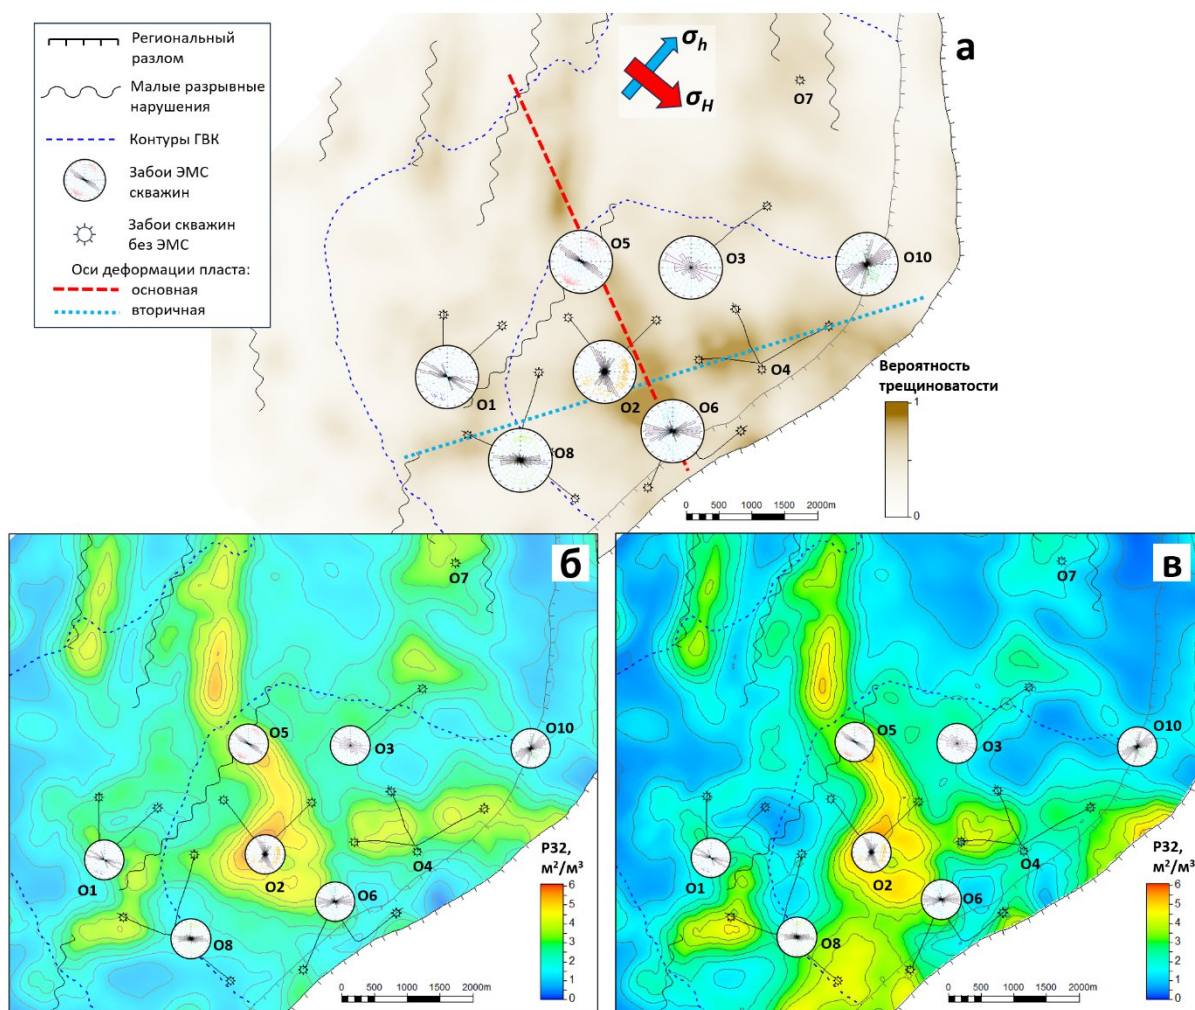
Ключевым компонентом пространственного тренда послужил куб «повторяемости» трещиноватых фаций [2], построенный по двухэтапной схеме машинного обучения (рис. 7). На первом этапе по данным расширенного комплекса ГИС методом многоуровневой графовой кластеризации MRGC (Multi-Resolution Graph-Based Clustering) на трех независимых от трещиноватости методах — акустическом (АК), нейтронном (НК) и плотностном (ПК) каротажах — выделены пять литотипов: трещинно-каверно-поровый и трещинно-поровый коллекторы, плотный известняк, доломит и ангидрит. Первые два литотипа представляли целевые «фации интереса» для последующего распространения. На втором этапе литотипы распространены в межскважинное пространство методом демократической ассоциации нейронных сетей (DNNA) на основе сейсмических атрибутов. Из исходных 39 атрибутов — включающих временной куб, результаты сейсмической инверсии и AVO-анализа, а также комплексные и трассовые производные — методом анализа главных компонент (PCA) выделен 21 ортогональный компонент, описывающий 95 % исходной информации. Качество сейсмостратиграфической привязки в целевом интервале характеризуется коэффициентом корреляции более 80 % [2].



**Рисунок 7.** Схема построения куба повторяемости трещиноватой фации [2]: совместная классификация скважинных литотипов (по данным MRGC) и сейсмических атрибутов (после снижения размерности методом PCA) выполняется методом DNNA в пяти реализациях с различными комбинациями обучающих и тестовых скважин; итоговое значение в каждой ячейке куба равно числу реализаций (от 0 до 5), классифицировавших ее как трещиноватую фацию; в качестве компонента тренда используются ячейки с повторяемостью 4–5

Алгоритм DNNA реализует ансамблевый подход с двухстадийным обучением: сначала набор независимых ИНС обучается на «жестких» данных (литология в скважинах в совокупности с PCA-атрибутами), затем точки межскважинного пространства с согласованным прогнозом большинства сетей отбираются системой голосования как «мягкие» данные и добавляются в обучающую выборку для финального этапа. Для оценки устойчивости классификации к составу обучающей выборки выполнено 5 реализаций прогноза с различными комбинациями 6 обучающих и одной «слепой» тестовой скважины. Анализ матриц восстановления классов показал, что коэффициент восстановления на «слепых» тестовых скважинах варьирует в пределах 30–45 % — закономерное следствие малого объема выборки, при котором исключение даже одной скважины существенно меняет результат обучения [2]. Несмотря на это, на всех пяти реализациях прослеживаются единообразные пространственные аномалии, ассоциированные с целевыми фациями. В качестве статистически устойчивой оценки сформирован куб «повторяемости» — сумма по реализациям, в которых данная ячейка классифицировалась как трещиноватая. В качестве компонента тренда использовались только ячейки с высокой повторяемостью (4–5 из 5 реализаций), для которых классификация как трещиноватой фации устойчива к составу обучающей выборки.

Куб повторяемости использовался исключительно для построения тренда Р32; прочие параметры DFN-модели — азимуты и углы падения трещин — распространялись независимо. Помимо куба повторяемости, тренд Р32 включал значение кривизны структуры, расстояние до разломов и осей складчатости, а также абсолютную глубину; их линейная комбинация формирует единый тренд, контролирующий стохастическое распространение интенсивности (рис. 8а).



**Рисунок 8.** Распределение средней по толщине пласта интенсивности трещиноватости: а) пространственный тренд вероятности трещиноватости, использованный в качестве входных данных для обоих вариантов моделирования; б) моделирование по данным скважин с ЭМС; в) моделирование с использованием полного фонда скважин, включая синтетические кривые ИНС

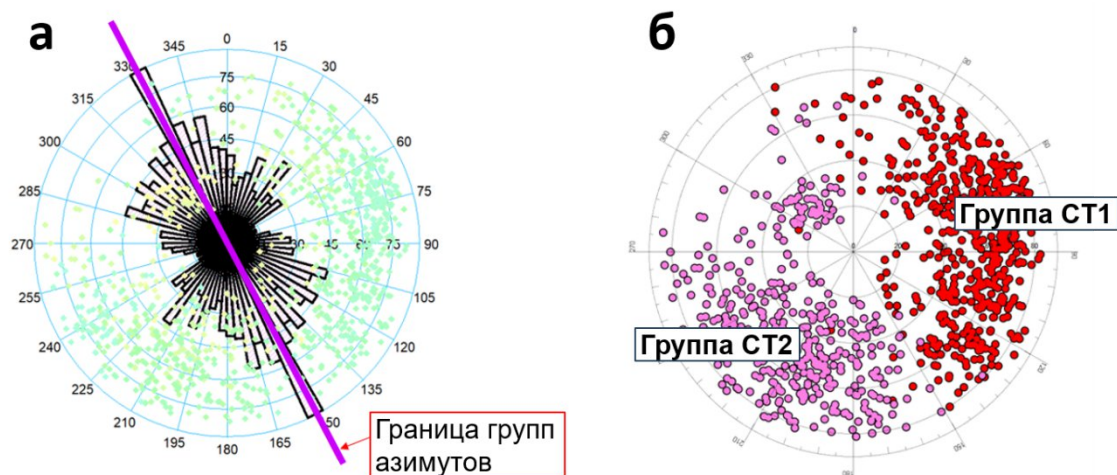
На рис. 8 приведены результаты пространственного моделирования интенсивности трещиноватости с использованием единого пространственного тренда (рис. 8а) на различных наборах скважинных данных: с использованием только 7 скважин с ЭМС (рис. 8б); с использованием полного фонда скважин, включая синтетические кривые

ИНС (рис. 8в). Сравнение показывает, что добавление скважинных точек с синтетической интенсивностью повышает детальность пространственного распределения и корректирует локальные особенности при сохранении глобального тренда.

Сейсмический тренд (куб повторяемости трещиноватой фации) и синтетические скважинные кривые интенсивности ИНС представляют независимые источники информации, принципиально различающиеся по масштабу и природе. Сейсмические данные описывают межскважинное пространство на масштабе сотен метров, отражая тектоническую структуру и фациальную изменчивость, однако лишены детальности отдельных скважинных наблюдений. Скважинные кривые, напротив, обеспечивают высокое вертикальное разрешение непосредственно в точках наблюдения, но не несут информации о латеральной изменчивости вне скважин. Совместное использование этих источников в рамках геостатистического моделирования с внешним трендом позволяет получить пространственное распределение, согласованное как с глобальной тектонической обстановкой, так и с локальными скважинными наблюдениями, что подтверждается сравнением карт на рисунке 8.

### ***Группировка трещин по азимутам падения (по данным ЭМС)***

Данные ЭМС по азимутальным характеристикам трещин свидетельствуют, что доминирующие азимуты простирания трещин ориентированы в направлении СЗ — ЮВ, и только вблизи купола и разлома структуры наблюдается локальное вращение осей трещиноватости (рис. 1). При этом одной линии простирания (СЗ — ЮВ) соответствуют два примерно равных по объему набора трещин с противоположно направленными азимутами падения. Для построения в сетке модели кубов — трендов азимуты падения трещин — набор трещин каждой скважины был разбит по преимущественному азимуту падения на две группы. На стереографической диаграмме проводилась ось разделения, ориентированная по преобладающему азимуту простирания трещин; трещины по разные стороны от нее формировали группы СТ1 и СТ2 (рис. 9). Необходимость разделения трещин на группы обусловлена тем, что при построении тренда в ячейках сетки происходит арифметическое осреднение азимуты — при этом противоположные азимуты падения сводятся в одной ячейке к среднему значению, не отражающему ни одну из двух фактических систем трещин.



**Рисунок 9.** Стереографическая диаграмма с а) границей группировки трещин противоположных азимутов падения и б) трещинами, разбитыми в группы СТ1 и СТ2

При деформации пласта трещины преимущественно формируются с азимутом простирания вдоль оси складки, поэтому для распространения азимутов падения трещин в объеме модели использованы тренды: градиент изменения кривизны пласта — для системы СТ2; антиградиент (противоположное градиенту направление) кривизны — для системы СТ1. Стохастический симулятор, используя трендовые кубы, генерирует в объеме модели два набора трещин. Каждый набор соответствует одной из групп (СТ1 или СТ2), сформированных по исходным данным ЭМС в скважинах.

### **Векторное осреднение азимутов**

Осреднение азимутальных величин ввиду цикличности угловой шкалы требует особого внимания для предотвращения получения некорректных результатов. Например, для группы СТ1 (рис. 9б) при использовании арифметического осреднения азимутов может получиться так, что для трещин с азимутами  $350^\circ$  и  $10^\circ$  средний азимут окажется равным  $180^\circ$ , что характеризует направление, прямо противоположное ожидаемому среднему азимуту  $0^\circ$ . Поэтому при распространении азимутов в объеме модели важно убедиться в том, что алгоритм использует векторное осреднение: каждый азимут преобразуется в компоненты  $\sin$  и  $\cos$ , которые усредняются отдельно, после чего результирующий азимут, восстановленный из средних значений компонент  $\sin$  и  $\cos$ , приводится в диапазон  $0-360^\circ$ .

### **Геометрические размеры и раскрытость трещин**

Раскрытость и геометрические параметры трещин (длина, высота) являются наиболее неопределенными характеристиками DFN-модели.

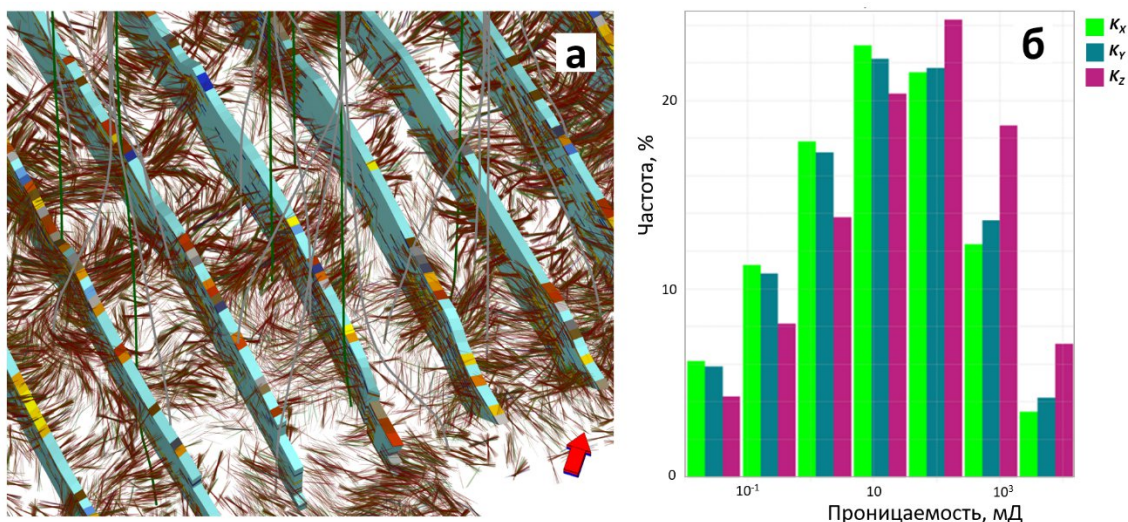
При этом раскрытость ( $b$ ) определяет проницаемость отдельной трещины кубически ( $k_f \sim b^3$ ) и подлжет последующей калибровке по данным гидродинамических исследований. Первичная оценка раскрытости ( $b$ ) выполнена на основе эмпирической зависимости от эффективного давления [6]:  $b = C \cdot P_{eff}^{-0.19}$ , где эффективное давление ( $P_{eff}$ ) рассчитано на основе горного, бокового и пластового давлений, с учетом коэффициента Пуассона. На втором этапе расчетная раскрытость откалибрована по гидропроводности  $kh$  из данных поинтервальных ГДИС [7] подбором множителя  $C$ . Средняя раскрытость трещин после калибровки на результаты ГДИС составила 34 мкм. Длина трещин варьировалась в ансамбле реализаций DFN; наилучшее воспроизведение данных межскважинного гидропрослушивания [8] достигнуто при среднем значении распределения около 100 м.

Высота трещин является одним из наиболее труднодоступных для прямого определения параметров: ни данные ЭМС, ни керновый анализ не позволяют оценить вертикальную протяженность трещин за пределами ствола скважины. Косвенная оценка верхней границы высоты получена по результатам серии поинтервальных ГДИС в скважине № О8 [7]: два раздельно испытанных интервала перфорации, разнесенных на 21 м по вертикали, демонстрируют кардинально различную продуктивность — трещиноватый коллектор в одном и поровый в другом. Это позволяет предположить, что проводящие трещины верхнего интервала не достигают нижнего, и принять 21 м в качестве верхней оценки  $P90$  распределения высот трещин. Среднее значение высоты трещин в модели составило 10 м при соотношении длины к высоте ( $L/H$ ) от 7 до 15.

## Преобразование трещин DFN в свойства регулярной сетки

Для применения DFN-модели в качестве основы гидродинамической модели двойной пористости / двойной проницаемости необходим перенос свойств дискретных трещин в ячейки геологической сетки.

Преобразование DFN-модели в свойства регулярной сетки (рис. 10а) выполнено методом Oda, который учитывает анизотропию, ориентацию и связанность трещинной сети. В результате получены пористость трещин, компоненты тензора проницаемости (рис. 10б) и коэффициент формы двойной среды ( $\sigma$ ), характеризующий интенсивность обмена флюидом между матрицей и трещинной системой. Метод преобразования не зависит от способа построения DFN-модели; однако качество входных данных — пространственное распределение интенсивности трещиноватости — определяет достоверность результата. Полученные свойства переданы в гидродинамическую модель двойной пористости; процедура адаптации модели на данные межскважинного гидропрослушивания и анализ результатов подробно изложены в работе [8].



**Рисунок 10.** Результаты построения DFN-модели: а) явные трещины с результирующим кубом ремасштабированной проницаемости (по одному из направлений); б) распределение ремасштабированных проницаемостей трещин в объеме сеточной модели

## Результаты и выводы

Представлен комплексный подход к построению модели дискретных трещин карбонатного пласта Афгано-Таджикского бассейна с широким применением методов машинного обучения на ключевых этапах моделирования.

Концепция развития трещиноватости, связывающая пространственное распределение и ориентацию трещин с осями складчатости, зонами максимальной кривизны пластов и стадиями формирования дизъюнктивных нарушений, использована в качестве геологического каркаса для всех этапов DFN-моделирования. Адекватность концепции подтверждается успешной адаптацией построенной на ее основе гидродинамической модели двойной пористости на данные межскважинного гидропрослушивания [8].

Модель ИНС, обученная на данных базового комплекса ГИС, обеспечила коэффициент детерминации  $R^2 = 0,90$  на тестовой выборке при стандартном случайном разделении данных. Кросс-валидация с последовательным исключением одной скважины (leave-one-well-out), воспроизводящая реальные условия прогнозирования на скважинах без ЭМС, показала  $R^2 \approx 0,7$ . Снижение по сравнению с базовой моделью закономерно и обусловлено потерей информации о локальных особенностях разреза исключенной скважины; при этом модель устойчиво воспроизводит основные интервалы повышенной трещиноватости.

Классификация сейсмических данных алгоритмом DNNA позволила получить устойчивый куб «повторяемости» трещиноватой фации, который

послужил одним из основных компонентов тренда пространственного распространения интенсивности. Комбинация этого тренда с геометрическими и структурными драйверами (кривизна структуры, расстояние до разломов и осей складчатости) обеспечила формирование согласованного описания трещиноватости в межскважинном пространстве.

Построенная DFN-модель послужила основой гидродинамической модели двойной пористости. Адаптация модели на данные межскважинного гидропрослушивания [8] показала, что расчетные безразмерные параметры двойной среды: коэффициент межпорового перетока  $\lambda \approx 10^{-7}$  и соотношение упругоёмкостей  $\omega \approx 0,1$  — согласуются с результатами аналитической интерпретации ГДИС [1]. Коэффициент формы двойной среды по результатам адаптации увеличился в 1,3 раза; поскольку интенсивность трещиноватости пропорциональна квадратному корню коэффициента формы, это соответствует увеличению интенсивности всего на ~14 %, что свидетельствует о достоверности исходной DFN-модели.

Предложенный подход к DFN-моделированию, основанный на интеграции ИНС-прогноза интенсивности трещиноватости с алгоритмом DNNA для построения сейсмического компонента пространственного тренда, продемонстрировал применимость для карбонатных трещиноватых коллекторов на ранних стадиях освоения, когда фонд скважин с ЭМС ограничен. Построенная DFN-модель формирует основу для проектирования эксплуатационных скважин на месторождении: пространственное распределение интенсивности трещиноватости, тензор проницаемости и параметры обменных процессов между матрицей и трещинами обеспечивают входные данные для оптимизации расположения добывающих скважин, выбора типа заканчивания и прогнозирования продуктивности. По мере расширения фонда скважин с ЭМС обучающие выборки ИНС и DNNA будут пополняться, что позволит уточнить пространственное распределение трещиноватости и провести сопоставление ИНС с ансамблевыми методами машинного обучения — Random Forest, XGBoost и стэкинг-ансамблями.

## Список литературы

1. Гаврилов А. В. Опыт проведения импульсного динамического исследования в трещиноватом газовом пласте / Гаврилов А. В., Тогаев Ш. Э., Абидов Х. А., Турсунова А. А., Исмагилов Р. Ф. // Актуальные проблемы нефти и газа. — 2023. — № 2(41). — С. 124–140. — <https://doi.org/10.29222/ipng.2078-5712.2023-41.art8>.
2. Kolbikova E. Rock typing and differentiated study of filtration properties of a fractured carbonate reservoir by using ML algorithms on the example of a deposit in Uzbekistan / Kolbikova E., Valiev R., Yanidis K. [et al.] // Presented at the 2024 SPE Caspian Technical Conference and Exhibition, Atyrau, Kazakhstan, 26–28 November. — 2024. — <https://doi.org/10.2118/223473-MS>.
3. Смирнов Н. Ю. Концептуальный подход при проведении DFN-моделирования / Смирнов Н. Ю., Стародубов В. А., Непоп Р. К. // ПРОНЕФТЬ. Профессионально о нефти. — 2025. — Т. 10. — № 2. — С. 6–13. — <https://doi.org/10.51890/2587-7399-2025-10-2-6-13>.
4. Nelson R. A. Geologic Analysis of Naturally Fractured Reservoirs, 2nd Edition / Nelson R. A. — Gulf Publishing, Houston, USA, 2001.
5. Raikar R. V. End depth computation in inverted semicircular channels using ANNs / Raikar R. V., Nagesh Kumar D., Dey S. // Flow Measurement and Instrumentation. — 2004. — № 15(5–6). — P. 285–293. — <https://doi.org/10.1016/j.flowmeasinst.2004.06.003>.
6. Козяев А. А. Подходы к моделированию карбонатного трещиноватого коллектора на примере месторождения Восточной Сибири / Козяев А. А., Смоленцев Е. И., Бибики А. Н., Закревский К. Е. // Научно-технический вестник ОАО «НК «Роснефть». — 2016. — № 1. — С. 11–15.
7. Gavrilov A. V. Hierarchical Well Testing Approach for Carbonate Gas Field Appraisal: A Case Study from Uzbekistan / Gavrilov A. V., Togaev S. E [et al.] // Presented at the 2025 SPE Annual Caspian Technical Conference and Exhibition, Baku, Azerbaijan, 25–27 November. — 2025. — <https://doi.org/10.2118/230378-MS>.
8. Гаврилов А. В. Интегрированный подход к определению параметров двойной среды на этапе разведки карбонатного месторождения / Гаврилов А. В., Тогаев Ш. Э., Клевицкий А. Г. // Нефтяная провинция. — 2026. — № 1(45). — С. 55–75. — <https://doi.org/10.25689/NP.2026.1.55-75>.

## References

1. Gavrilov A. V. Opyt provedeniya impul'snogo dinamicheskogo issledovaniya v treshchinovatom gazovom plaste [Experience of interwell interference testing in a fractured gas reservoir] / Gavrilov A. V., Togaev Sh. E., Abidov Kh. A. [et al.] // Actual Problems of Oil and Gas. — 2023. — № 2(41). — P. 124–140. — <https://doi.org/10.29222/ipng.2078-5712.2023-41.art8> (in Russ.).
2. Kolbikova E. Rock typing and differentiated study of filtration properties of a fractured carbonate reservoir by using ML algorithms on the example of a deposit in Uzbekistan / Kolbikova E., Valiev R., Yanidis K. [et al.] // Presented at the 2024 SPE Caspian Technical Conference and Exhibition, Atyrau, Kazakhstan, 26–28 November. — 2024. — <https://doi.org/10.2118/223473-MS>.
3. Smirnov N. Y. Kontseptual'nyy podkhod pri provedenii DFN-modelirovaniya [Conceptual approach to DFN modeling] / Smirnov N. Y., Starodubov V. A., Nepop R. K. // PRONEFT. Professionally about oil— 2025. — Vol. 10. — № 2. — P. 6–13. — <https://doi.org/10.51890/2587-7399-2025-10-2-6-13>.
4. Nelson R. A. Geologic Analysis of Naturally Fractured Reservoirs, 2nd Edition / Nelson R. A. — Gulf Publishing, Houston, USA, 2001.
5. Raikar R. V. End depth computation in inverted semicircular channels using ANNs / Raikar R. V., Nagesh Kumar D., Dey S. // Flow Measurement and Instrumentation. — 2004. — № 15(5–6). — P. 285–293. — <https://doi.org/10.1016/j.flowmeasinst.2004.06.003>.
6. Kozyaev A. A. Podkhody k modelirovaniyu karbonatnogo treshchinovotogo kollektora na primere mestorozhdeniya Vostochnoy Sibiri [Approaches to modeling of carbonate fractured reservoir by the example of Eastern Siberia field] / Kozyaev A. A., Smolentsev E. I., Bibik A. N. [et al.] // Scientific and technical bulletin of Rosneft Oil Company. — 2016. — No. 1. — Pp. 11–15.
7. Gavrilov A. V. Hierarchical Well Testing Approach for Carbonate Gas Field Appraisal: A Case Study from Uzbekistan / Gavrilov A. V., Togaev S. E [et al.] // Presented at the 2025 SPE Annual Caspian Technical Conference and Exhibition, Baku, Azerbaijan, 25–27 November. — 2025. — <https://doi.org/10.2118/230378-MS>.
8. Gavrilov A. Integrirovanny podkhod k opredeleniyu parametrov dvoynoy sredy na etape razvedki karbonatnogo mestorozhdeniya [An integrated approach for dual-medium characterization at carbonate field appraisal stage] / Gavrilov A. V, Togaev Sh. E., Klevitskiy A. G. // Neftyanaya Provintsiya. — 2026. — No. 1(45). — Pp. 55–75. — <https://doi.org/10.25689/NP.2026.1.55-75> (in Russ.).