

DOI: <https://doi.org/10.25689/NP.2024.4.104-120>

EDN PTYGQQ

УДК 550.834.05

**Использование нейронных сетей Колмогорова  
при прогнозировании коллекторских свойств  
на примере месторождений Западной Сибири**

*Хусаинов Г.В., Ковалькова А.С.*

*ООО «Тюменский нефтяной научный центр», Тюмень, Россия*

**The use of Kolmogorov neural networks  
in prediction of reservoir properties  
on the example of deposits of Western Siberia**

*G.V. Khusainov, A.S. Kovalkova*

*Tyumen Oil Research Center LLC, Tyumen, Russia*

**E-mail: [GV\\_Khusainov2@tnnc.rosneft.ru](mailto:GV_Khusainov2@tnnc.rosneft.ru)**

**Аннотация.** Применимость использования алгоритмов машинного обучения для решения задач в области сейсмической интерпретации является актуальным вопросом. В данной статье представлено сравнение результатов тестирования алгоритмов машинного обучения, интегрированных в ПО IP-Seismic. Полученные результаты могут быть использованы для построения трендов в процессе моделирования, оценки различных сценариев и анализа разброса начальных геологических запасов.

**Ключевые слова:** *нейронные сети, сейсморазведка, прогноз, ФЭС, геологическая модель*

**Для цитирования:** Хусаинов Г.В., Ковалькова А.С. Использование нейронных сетей Колмогорова при прогнозировании коллекторских свойств на примере месторождений Западной Сибири // Нефтяная провинция.-2024.-№4(40).-С. 104-120. - DOI <https://doi.org/10.25689/NP.2024.4.104-120>. - EDN PTYGQQ

**Abstract.** The applicability of using machine learning algorithms to solve problems in the field of seismic interpretation is an urgent issue. This article presents a comparison of the results of testing machine learning algorithms integrated into IP-Seismic software. The ob-

tained results can be used to build trends in the modeling process, evaluate various scenarios and analyze the spread of initial geological reserves.

**Key words:** *neural networks, seismic exploration, prediction, reservoir property, geological model*

**For citation:** G.V. Khusainov, A.S. Kovalkova Ispol'zovaniye neyronnykh setey Kolmogorova pri prognozirovanii kollektorskiykh svoystv na primere mestorozhdeniy Zapadnoy Sibiri [The use of Kolmogorov neural networks in prediction of reservoir properties on the example of deposits of Western Siberia]. Neftyanaya Provintsiya, No. 4(40), 2024. pp. 104-120. DOI <https://doi.org/10.25689/NP.2024.4.104-120>. EDN PTYGQQ (in Russian)

## Введение

В последние годы наблюдается увеличение интереса к применению методов машинного обучения, особенно в контексте оценки коллекторских свойств в рамках сейсмической интерпретации. Данная задача является сложной по причине нелинейности и неоднородности геологической среды. Атрибутный анализ и инверсия, основанные на классических подходах к определению линейных связей между ГИС и сейсмическими данными, не всегда обеспечивают достаточную точность моделирования емкостных свойств пласта и определения сильной корреляционной зависимости с прогностическими свойствами.

Ключевая проблема - поиск функциональной аппроксимации сейсмических данных к данным каротажа с целью последующего распространения на всю площадь объекта.

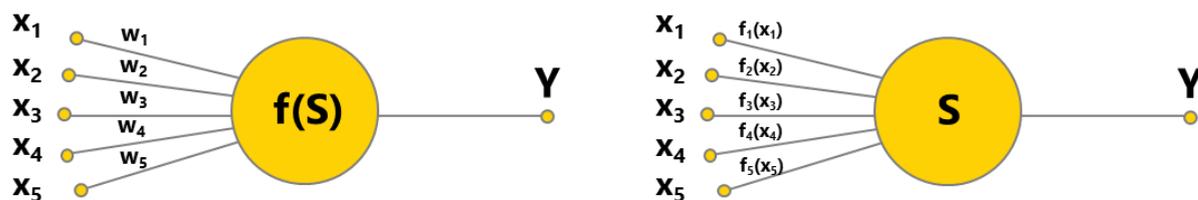
Для нивелирования неопределенностей во время сейсмической интерпретации использовался метод прогнозирования коллекторских свойств, основанный на анализе данных сейсморазведки и применении нейронных сетей Колмогорова [2].

Алгоритмы машинного обучения, интегрированные в ПО «IP-Seismic» («ООО «Лаборатория Приезжева»), уже использовались при прогнозировании свойств пласта [5,6,7] на нефтяных месторождениях.

## Методы

В рамках решения задачи использовалось ПО «IP Seismic» («ООО «Лаборатория Приезжева»), при этом ключевую роль в процессе играли алгоритмы, основанные на нейронных сетях Колмогорова. Отличительной чертой нейросетей Колмогорова является сложная и глубокая структура, что выделяет их на фоне традиционных моделей нейросетей. В отличие от привычного метода построения архитектуры сети с прямыми связями, где слои нейронов последовательно обрабатывают и передают данные, нейросети Колмогорова обладают возможностью формирования более комплексной нелинейной структуры благодаря рекуррентной архитектуре, что позволяет осуществлять соединения между нейронами в различных конфигурациях, обеспечивая высокую эффективность обработки информации.

Входные данные одного нейрона могут стать выводами для другого, как показано на рис. 1. Каждый нейрон применяет уникальную нелинейную функцию к своим входам, что значительно увеличивает их гибкость. Благодаря наличию большего количества скрытых слоев, нейросети, разработанные Колмогоровым, способны более эффективно анализировать сложные наборы данных. Обучение этих сетей производится с использованием смешанного алгоритма, сочетающего в себе генетические и градиентные методы. Для достижения надежных результатов прогнозирования применяются методы, основанные на теореме о монотонности функций от Колмогорова и техники регуляризации по Тихонову.



*Рис. 1. Сравнение классического нейрона и полнофункционального нейрона Колмогорова*

В процессе работы можно прогнозировать распределение коллектора по скважинным данным, в 2D и 3D вариантах, а также другие ключевые параметры для оценки качества резервуара. Рекомендуется применение стохастического подхода, предполагающего создание множества прогнозов путём исключения определённых скважин из каждого расчёта для изучения вариативности результатов. Данный подход позволяет генерировать кубы данных, отражающие различные уровни вероятности (P10, P50, P90), средние значения и стандартные отклонения, также глубинные кубы данных могут быть эффективно интегрированы в 3D моделирование, служа объёмным трендом для оценки и прогнозирования потенциальных изменений в трёхмерной модели коллектора.

Применение нейронных сетей в прогнозных вычислениях можно разделить на два ключевых этапа.

Первый этап - обучение нейронных сетей, используя необходимый набор данных:

1. Значение прогнозируемого параметра, определенное в конкретной точке вдоль ствола скважины;

2. Вектор переменных, используемый для выполнения прогноза. В данном контексте этот вектор состоял из данных сейсмического по трассе заданного куба (или нескольких кубов) выше и ниже точки прогноза с параметром вдоль ствола скважины. Возможно использовать как и кубы полученные по результатам инверсии, так и амплитудные кубы. Кроме того, возможно использовать кубы в глубинном масштабе, для того чтобы в дальнейшем использовать их при построении геологической модели.

Обучающий массив может иметь большую размерность, так как в нем используются все точки на заданных скважинах. Выборка этих точек и диапазон зоны прогноза могут быть ограничены интервалом целевого пласта. Если заданный пласт можно разбить на пропластки дополнительными поверхностями, то эти поверхности также используются для определения

низкочастотного тренда при прогнозе. В случае большого количества скважин на изучаемом участке предлагается использовать режим отдельного обучения нейронных сетей по каждой скважине, что позволяет получить набор отдельных обученных нейронных сетей, соответствующих каждой скважине. В процессе выполнения расчёта результативного куба используются несколько нейронных сетей с ближайших к расчётной трассе скважин. Значения на этой трассе вычисляются как средневзвешенное по результатам применения нейронных сетей, с весом, обратным расстоянию до соответствующих скважин, и с учётом защитного радиуса, задаваемого пользователем. Количество ближайших скважин также задаётся пользователем.

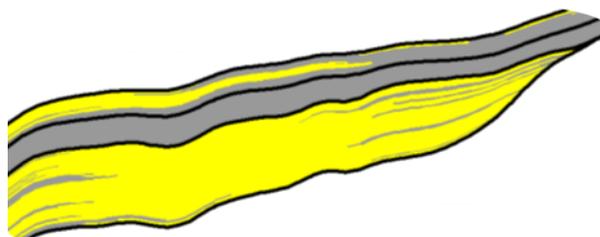
Второй этап — вычисление прогнозных кубов на основе обученной на первом этапе нейронной сети. На вход нейронной сети подаются сейсмические кубы, которые использовались при обучении. Для оценки точности прогнозных построений используется кросс-валидационный подход, суть которого в выполнении многократных прогнозов на основе обучения на случайной части обучающего массива с удалением части скважин. В результате многократных прогнозов вычисляются кубы среднего прогноза стандартного отклонения P10, P50 и P90.

### **Прогноз свойств пласта**

В ходе работы подход был апробирован на газоконденсатных активах, территориально расположенных в ЯНАО. Метод нейросетевого прогноза применялся при построении геологических моделей пластов с различными геологическими особенностями с целью улучшения прогностической способности моделей и дальнейшего планирования эксплуатационного бурения в условиях геологических неопределенностей.

## Пласт БУ16

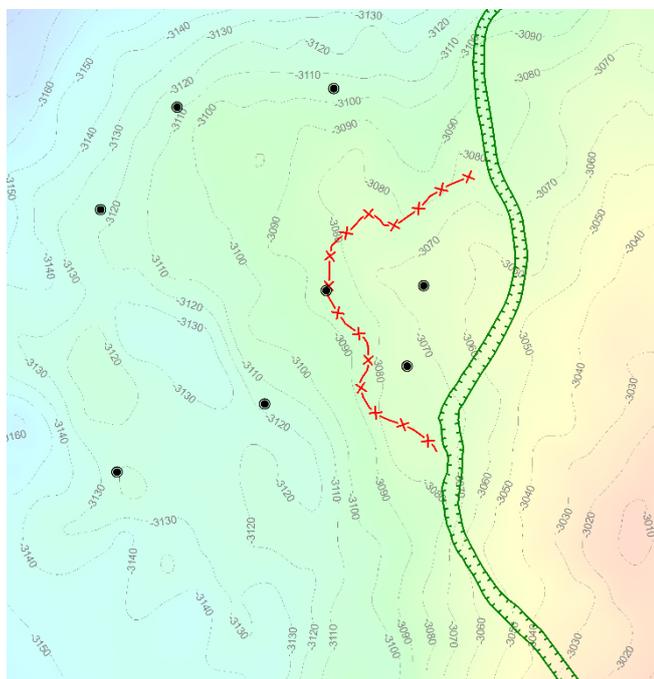
В первом примере в качестве объекта исследования выступал пласт БУ16 со сложным клиноформенным строением (Рис. 2). С седиментологической точки зрения осадки образовывались в условиях дельты волнового типа. Залежь структурно-литологическая, пластово-сводовая.



*Рис. 2. Геологический разрез пласта БУ16*

Из-за сложности строения пласта и недостаточной степени изученности отмечаются следующие неопределенности:

- малое количество скважин (8 разведочных скважин) и неравномерная сетка разбуривания в пределах месторождения (Рис. 3);



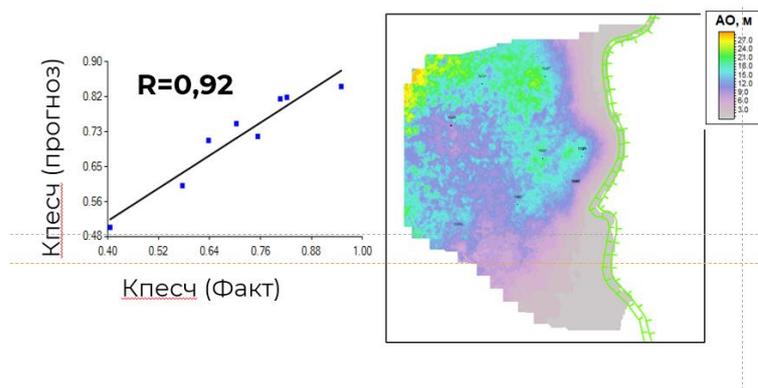
*Рис. 3. Структурная карта БУ16*

- отсутствие универсального площадного атрибута для прогнозирования коллекторских свойств для пластов со сложным клиноформенным

строением. При анализе атрибутов важными факторами для получения детального сейсмического тренда являются правильный выбор нарезки и окна для измерения атрибутов. Неверный выбор этих параметров может привести к упущению части информации о коллекторе, что в свою очередь снизит корреляцию между прогнозом и фактическими данными, делая результаты непригодными для включения в геологическую модель.

Одним из вариантов решения проблемы поиска связи между скважинными данными с сейсмической информацией рассматривается использование нейронных сетей Колмогорова для построения 2D и 3D тренда.

В ходе построения поверхностного тренда были получены карты распространения песчаности. Расчет производился по алгоритму TNN regression. В качестве входной информации использовались результаты синхронной инверсии - упругие свойства (отношение скорости продольной и поперечной волны, акустический и сдвиговый импеданс). По итогам прогноза был получен двумерный сейсмический тренд с сильной корреляционной зависимостью (0,92) со скважинными данными. Результаты представлены на Рис. 4.



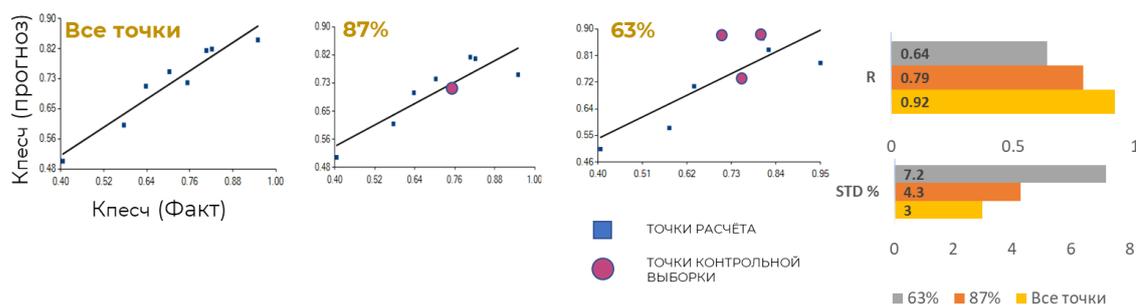
*Рис. 4. Двухмерный сейсмический тренд песчаности*

Однако у нейронных сетей есть свои недостатки, поэтому задача интерпретатора заключается в их решении. Для этого важно определиться с критериями, по которым будет оцениваться прогноз, в данном случае на качественном уровне важно оценить его адекватность с геологической

точки зрения - убедиться в отсутствии аномальных значений в межскважинном пространстве, что подтверждает контрольную зону выклинивания пласта.

В рамках количественной оценки были выполнены:

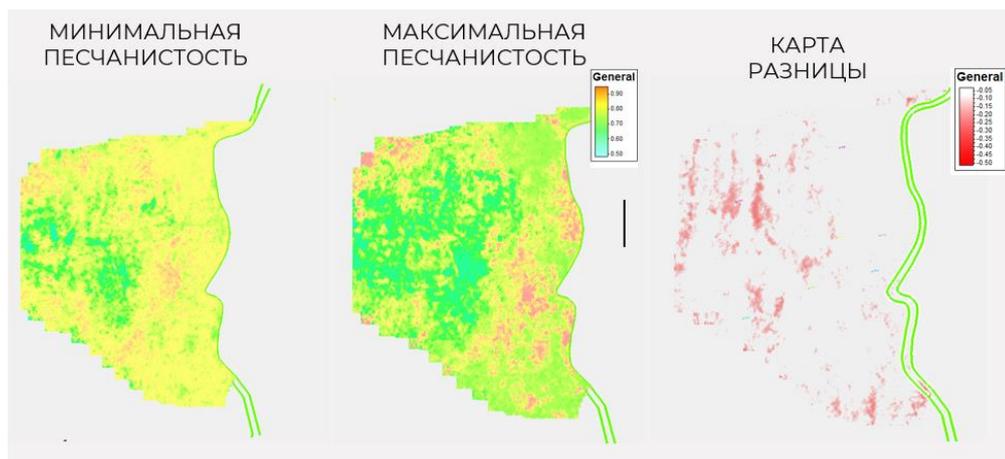
- кросс-валидационный анализ — метод, который использует только часть скважинной информации для оценки влияния полученного прогноза на общее распределение. Результаты данного анализа представлены на рис. 5, где приведено сравнение прогнозных значений для всех имеющихся значений, а также с исключением одной (13 % от общей выборки) и трех (37 % от общей выборки) скважин. По результатам сравнения видно, что даже при исключении до 37 % точек из обучения, прогнозные значения демонстрируют достаточно сильную корреляцию (0,64) с фактическими данными (Рис. 5).



**Рис. 5. Результаты кросс-валидации**

- анализ стабильности результатов – выявить потенциальную неустойчивость решения. При предоставлении идентичной информации для прогнозирования нейронные сети выдают значительно различные результаты на выходе при нескольких расчетах. Для снижения неопределенности используется встроенный алгоритм валидации, основанный на многократных прогнозах с частичным использованием скважин для обучения. Для активации данной функции был запущен процесс «validation option – number realization», где было установлено необходимое количество реализаций. В данном случае было рассчитано 25 реализаций и количество исключаемых точек из прогноза.

По результатам выполнения стохастических расчетов, генерируются карта минимального, среднего, максимального прогноза значений песчаности, стандартное отклонение прогнозов и карты P10, P50, P90. Для выявления корректности расчетов, рассчитывалось отклонение между максимальным и минимальным результатом прогнозов, что составило 6,8 % (Рис. 6)



**Рис. 6. Результат выполнения стохастических расчетов**

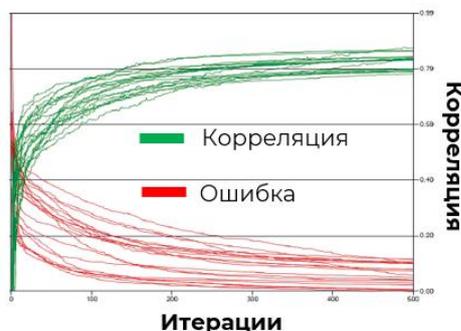
Проверка прогнозных карт позволяет применять их в дальнейшем в геологической модели, но полученные карты не дают понимание о вертикальном распространении свойств в пределах пласта, в связи с этим выполнялось построение 3D тренда. Прежде всего стоит отметить, что 2D построения выполнялись на основе сейсмических данных во временной области, а геологическая модель строится в глубинной области, поэтому для применения трехмерного тренда при конвертации временного куба важно корректно применить закон «время-глубина». Для этого с использованием карт изохрон и структурных карт строится трехмерная скоростная модель, с помощью которой сейсмический куб конвертируется в глубинную область. Преимущество использования куба вероятности распространения коллектора - при выполнении прогноза могут участвовать горизонтальные скважины, в двухмерном прогнозе такой тип скважин, которые не вскрыли всю толщу пласта, исключаются из входных данных для обучения.

### Этапы построения трехмерного прогноза

В качестве исходных данных использовались структурные карты с целью выделения целевой области прогноза - пласт БУ16. Также, как и при 2D построениях использовались кубы полученные по результатам синхронной инверсии упругие свойства, но только уже переведенные в глубинную область и значения оцененного коэффициента песчанистости вдоль стволов скважин.

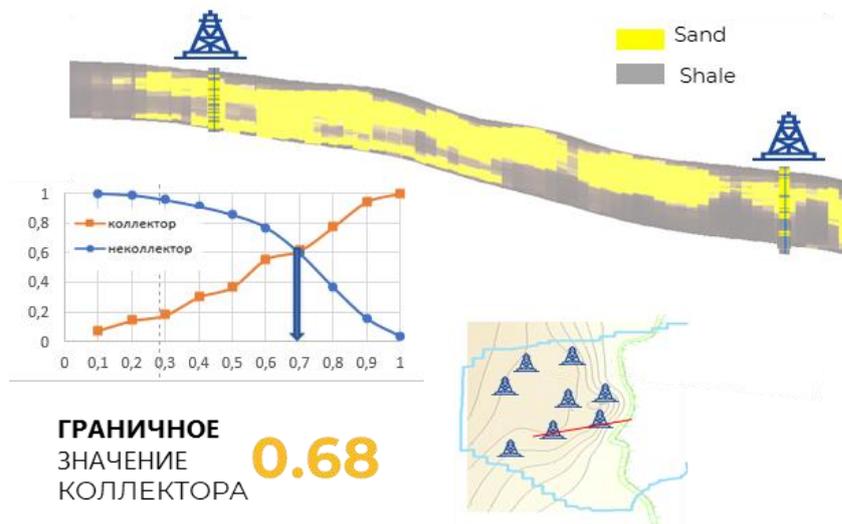
При выполнении прогноза с помощью нейронных сетей происходит последовательное выполнение этапов, начиная с обучения нейронной сети. Все коэффициенты в нейронной сети настраиваются с целью минимизации объективной функции.

Для внедрения элементов стохастических алгоритмов на каждой итерации обучения (проведено 25 итераций) из обучающей выборки исключалась определенная доля скважин (в данном случае 25 %). В результате такой обработки алгоритм генерирует вероятностные реализации кубов для оценки наличия коллектора (P10, P50, P90), куб среднего значения и куб дисперсии, которые отражают уровень неопределенности выполненного прогноза. По результатам для каждого из вариантов был рассчитан график обучения, продемонстрированный на рис. 7, где красные кривые показывают уменьшение целевой функции; зеленые кривые - рост коэффициента корреляции в процессе обучения. В среднем коэффициент корреляции для всех вариантов обучения составил 0,82.

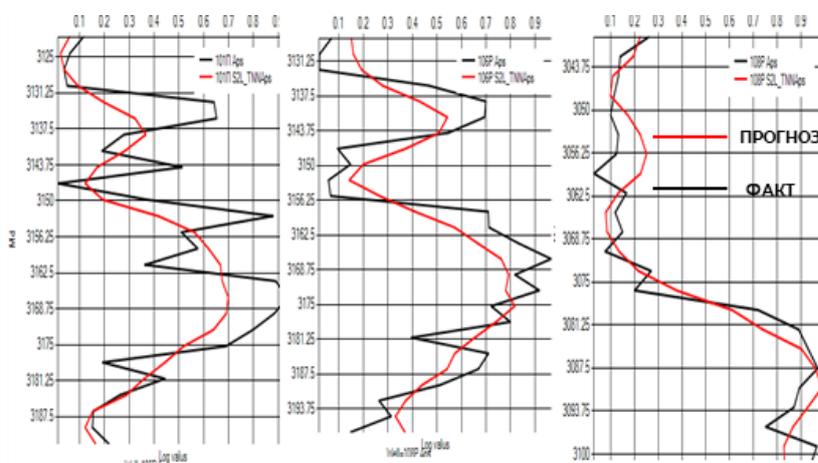


*Рис. 7. График обучения 25 вариантов нейронной сети со случайным удалением 25% скважин*

После этапа обучения выполнялось вычисление итогового куба распространения песчаности. Данный куб преобразовался в дискретные значения «коллектор – не коллектор» на основе применения граничного значения, полученного по данным ГИС (Рис. 8). В текущей реализации наблюдается хорошая сходимость синтетических кривых из прогнозного куба с данными ГИС (Рис. 9), но не так детально, как по кривой ГИС. Данный аспект связан с отличием разрешающей способности данных геофизических исследований скважин с данными, полученными из сейсмической съёмки. Прогноз имеет тренд распространения и в большинстве случаев повторяется со значением скважинной информации.



**Рис. 8. Разрез через прогнозный куб литотипов**



**Рис. 9. Планшет скважин с фактическими и прогнозными кривыми**

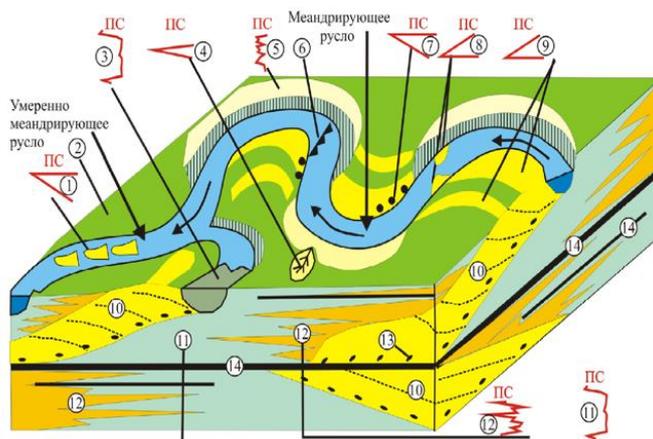
## Пласты ПК19-20

Прогнозирование фациальных обстановок в пределах группы пластов ПК19-20 проводилось во втором примере исследования. Согласно представленной концептуальной модели, отложения пластов ПК19-20 формировались в различных обстановках осадконакопления. Например, пласт ПК<sup>19</sup> накапливался в условиях приливно-отливной равнины и прилегающей к ней низменности, периодически заливаемой морем. Пласт ПК<sup>20</sup> образовывался в затопленной низменной равнине и прилегающих к ней приливно-отливных отмелях. Пласт ПК<sub>20</sub> формировался в условиях низменной равнины, находящейся в контакте с приливно-отливной зоной.

Для моделирования различных фаций в пластах ПК<sub>19-20</sub> было принято решение объединить их в группы макрофаций из-за схожих свойств и невозможности их индивидуального выделения в поле упругих параметров. Таким образом, более 20 фаций были сгруппированы следующим образом: болото (SW), глинистая приливно-отливная отмель (MTF), смешанная глинистая приливно-отливная отмель (MSTF), приливно-отливный канал (ПК<sub>19</sub>) (ТС), и речное русло с влиянием приливно-отливных процессов (ПК<sub>20</sub>) (FCt). Это позволило провести моделирование и прогнозирование фациальных обстановок в данных пластах эффективнее.

Анализ форм кривых  $\alpha$ ПС, ГК, ГГКп и других позволил определить характеристики отложений различных типов, таких как флювиальные русла (FCt), приливно-отливные каналы (ТС) и глинистые приливно-отливные отмели (MTF). Модели В.С. Муромцева [8] использовались в качестве методической основы для выделения фаций по данным ГИС. При этом отложения флювиальных русел характеризуются блоковой или колоколовидной формой кривых ПС и ГК, при низких значениях ГК и значениях  $\alpha$ ПС больше 0,7. Отложения приливно-отливных каналов также имеют колоколовидную форму кривых ПС и ГК с низкими значениями ГК и  $\alpha$ ПС боль-

ше 0,6. Глинистые приливно-отливные отмели отличаются положительной аномалией кривых ПС и ГК, высокими значениями ГК и ГГК-П, а также значениями  $\alpha$ ПС меньше 0,5. Отложения маршей и болот обладают низкими значениями ГК и ГГК-П, в то время как отложения смешанных приливно-отливных отмелей выделяются своей изрезанной формой кривых ПС и ГК, средними значениями ГК и значениями  $\alpha$ ПС в диапазоне от 0,3 до 0,7.



**Рис. 10. Концептуальная модель ПК19-20 [8]**

На этой территории проводится активное бурение вертикальных и горизонтальных скважин, поэтому одной из основных задач является подтверждение прогностической способности геологической модели. В 2020 году проведена переобработка и переинтерпретация сейсморазведочных данных на данной площади. Согласно полученным данным, производился прогноз с применением нейронных сетей Колмогорова. На этапе прогнозов учитывались скважины пробуренные на момент выполнения интерпретации всей сейсмо-геологической информации. По итогу были построены карты с оценкой вероятности распространения фаций, анализ построений выявил корреляционные связи разной степени достоверности для пластов  $ПК_{19}^1$ ,  $ПК_{19}^2$ ,  $ПК_{20}$  (Табл. 1). Полученные 2Д тренды с коэффициентом корреляции выше 0,6 применялись для построения трехмерной геологической модели.

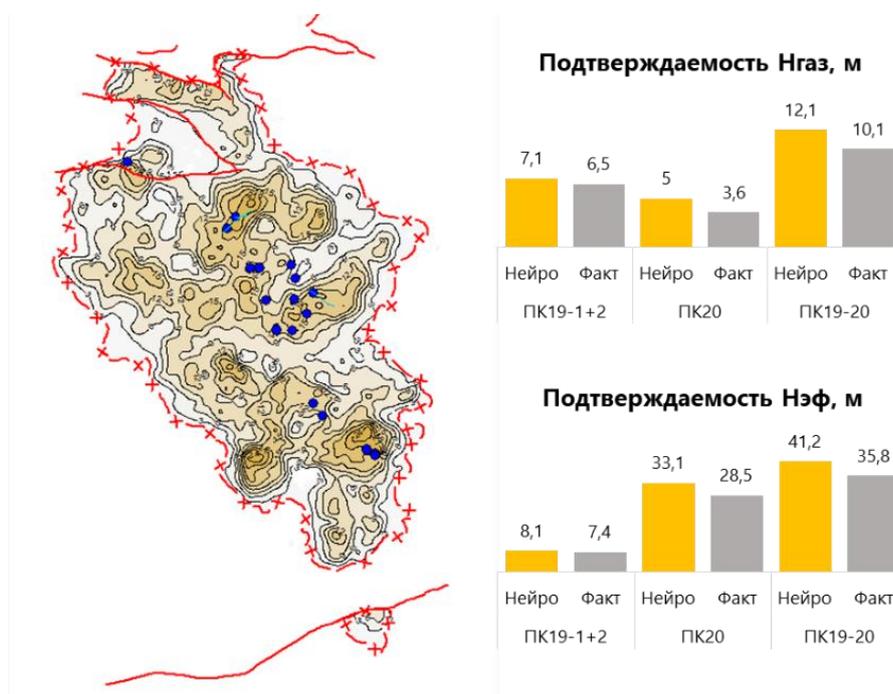
Таблица 1

*Корреляция вероятности распространения фаций в точках скважин с прогнозными значениями по результатам нейросетевого прогноза*

Пласт	Фация	Код фации	Коэффициент корреляции
ПК19-1	Болото	SW	0,69
	Глинистая приливно-отливная отмель	MTF	0,7
	Смешанная приливно-отливная отмель	MSTF	0,69
	Приливно-отливной канал	TC	0,69
ПК19-2	Болото	SW	0,75
	Глинистая приливно-отливная отмель	MTF	0,68
	Смешанная приливно-отливная отмель	MSTF	0,75
	Приливно-отливной канал	TC	0,72
ПК20	Болото	SW	0,7
	Глинистая приливно-отливная отмель	MTF	0,48
	Смешанная приливно-отливная отмель	MSTF	0,68
	Речное русло	FCt	0,63

Одним из основных критериев качества применяемых сейсмических трендов, как основы для построения фациальной геологической модели является мониторинговый анализ, направленный на оценку подтверждаемости прогноза текущим бурением. После построения модели было пробурено 17 скважин, которые вскрыли всю толщу пластов ПК19-20. По результатам бурения была проведена оценка сходимости прогнозных эффективных и газонасыщенных толщин, среднее отклонение по всей выборке скважин по суммарной эффективной и газонасыщенной толщине пластов ПК19-20 составило 5,3 и 2 метра от факта соответственно, при этом наблюдается завышение в обоих случаях. На Рис. 11 представлены гисто-

граммы со средними фактическими и прогнозными значениями по новым пробуренным скважинам.



*Рис. 11. Карта ГНТ пластов ПК19-20 и гистограмма средних значений прогнозных и фактических параметров*

### Заключение

Применение нейронных сетей Колмогорова показала эффективность для пластов с разными фаціальными обстановками. Данный подход позволяет как прогнозировать ФЕС среды, так и вероятность распространения фаций с сильной корреляционной зависимостью.

Нейросетевой прогноз позволил получить хорошую сходимость прогнозных и фактических значений по новым скважинам, которые не были пробурены на момент выполнения прогноза. Также позволил получить довольно сильную связь по пласту БУ16 со сложным геологическим строением, полученный результат был проверен на корректность расчетов, так как нейронные сети имеют свои недостатки, эффект переобучения которых в данном ПО удастся избежать путем тестирования различных параметров регуляризации. И второе ограничение – поиск глобального минимума. Это

ограничение в данном ПО удастся минимизировать путем применения эволюционных алгоритмов.

Также данный метод позволяет строить трехмерный прогнозный куб, достоинством которого является использование наклонных и горизонтальных скважин. Данный подход является пригодным для целей сопровождения бурения скважин, принятия оперативных решений о корректировке траектории скважин с целью увеличения эффективной проходки.

### Список литературы

1. Kobrunov A., Priezzhev I. Hybrid combination genetic algorithm and controlled gradient method to train a neural network // *Geophysics*. — 2016. — vol. 81. — № 4. — Pp. 1–9.
2. Приезжев И.И. Нейронные сети нового поколения на основе теоремы Колмогорова и их применение для прогнозно-инверсионных построений // *ГеоЕвразия*, Москва, 3–5 февраля. — 2020.
3. Priezzhev I., Shmaryan L., Bejarano G. Non-linear multi trace seismic inversion using neural network and genetic algorithm — “Genetic Inversion” // *Annual Meeting St Petersburg, EAGE, Extended Abstracts*. — 2008.
4. Гайфулина Е.Ф., Решетников А.А., Швыдкой В.С., Дорохов А.Р. Стохастическая инверсия для включения сейсмических данных в трехмерное моделирование // *Экспозиция Нефть Газ*. 2022. № 8. С. 16–21. DOI: 10.24412/2076-6785-2022-8-16-21
5. Пример использования нейронных сетей Колмогорова при прогнозировании свойств пласта Покурской свиты в Западной Сибири / И.И. Приезжев [и др.] // *Геофизика*. — 2022. — №1. — С. 58-63. — URL: <https://rucont.ru/efd/873051> (дата обращения: 20.08.2024)
6. Приезжев, И.И. Интеллектуальный анализ геолого-геофизических данных (обзор применяемых алгоритмов) / И.И. Приезжев, Р.А. Ахметзянов // *Геофизика*. — 2023. — № 1. — С. 2-11. — DOI: 10.34926/geo.2023.90.81.001. — EDN JSGWUX.
7. Селетков, И. А. Опыт применения машинного обучения при прогнозе геологического разреза по сейсмическим данным / И.А. Селетков, Д.А. Бельшев, И.И. Приезжев // *Геофизика*. — 2021. — № 5. — С. 12-18. — EDN HOZCDW.
8. Муромцев В.С. Электрометрическая геология песчаных тел – литологических ловушек нефти и газа. – Л.: Недра, 1984. – 260 с.

### References

1. Kobrunov A., Priezzhev I. Hybrid combination genetic algorithm and controlled gradient method to train a neural network. *Geophysics*, 2016. Vol. 81, No. 4, pp. 1–9. (in Russian)
2. Priezzhev I.I. *Nejronnye seti novogo pokoleniya na osnove teoremy Kolmogorova i ih primenenie dlya prognozno-inversionnyh postroenij* [Next-generation neural networks based on Kolmogorov theorem and their application for predictive inverse modeling]. *GeoEurasia*, Moscow, February 3-5, 2020 (in Russian)
3. Priezzhev I., Shmaryan L., Bejarano G. Non-linear multi trace seismic inversion using neural network and genetic algorithm. *Genetic Inversion. Annual Meeting St Petersburg, EAGE, Extended Abstracts*. 2008

4. Gaifullina E.F., Reshetnikov A.A., Shvydkoi V.S., Dorokhov A.R. *Stokhasticheskaya inversiya dlya vklyucheniya sejsmicheskikh dannykh v trekhmernoe modelirovanie* [Stochastic inversion for including seismic data in 3D modeling]. *Ekspozitsiya Neft Gaz* [Oil and Gas Exhibit]. 2022, No. 8, pp. 16–21. DOI: 10.24412/2076-6785-2022-8-16-21 (in Russian)
5. Priezzhev I.I. *Primer ispolzovaniya nejronnykh setej Kolmogorova pri prognozirovanii svoystv plasta Pokurskoj svity v Zapadnoj Sibiri* [The example of neural Kolmogorov networks in reservoir properties forecast within West Siberia Pokur suite]. *Geofizika* [Geophysics]. 2022, No.1, pp. 58-63. URL: <https://rucont.ru/efd/873051> (in Russian)
6. Priezzhev I.I., Akhmetzyanov R.A. *Intellectualnyj analiz geologo-geofizicheskikh dannykh (obzor primenyaemykh algoritmov)* [Intellectual analysis of geological and geophysical data (overview of the algorithm used)]. *Geofizika* [Geophysics]. 2023, No. 1, pp. 2-11. DOI: 10.34926/geo.2023.90.81.001. – EDN JSGWUX. (in Russian)
7. Seletkov I.A., Belyshev D.A., Priezzhev I.I. *Opyt primeneniya mashinnogo obucheniya pri prognoze geologicheskogo razreza po sejsmicheskim dannym* [Experience in applying machine learning to geological section prediction from seismic data]. *Geofizika* [Geophysics]. 2021, No. 5, pp. 12-18. EDN HOZCDW (in Russian)
8. Muromtsev V.S. *Elektrometricheskaya geologiya peschanyh tel – litologicheskikh lovushek nefti i gaza* [Electrometric geology of sand bodies as oil and gas lithological traps]. *Leninograd: Nedra Publ.*, 1984, 260 p. (in Russian)

#### Сведения об авторах

*Хусаинов Георгий Вячеславович*, ведущий специалист, ООО «Тюменский нефтяной научный центр»

Россия, 625000, Тюмень, ул. Осипенко, 79/1

E-mail: [GV\\_Khusainov2@tnnc.rosneft.ru](mailto:GV_Khusainov2@tnnc.rosneft.ru)

*Ковалькова Анастасия Сергеевна*, ведущий специалист, ООО «Тюменский нефтяной научный центр»

Россия, 625000, Тюмень, ул. Осипенко, 79/1

E-mail: [AS\\_Kovalkova@tnnc.rosneft.ru](mailto:AS_Kovalkova@tnnc.rosneft.ru)

#### Authors

*G.V. Khusainov*, Leading Specialist, Tyumen Oil Research Center LLC

79/1, Osipenko Str., 625000, Tyumen, Russian Federation

E-mail: [GV\\_Khusainov2@tnnc.rosneft.ru](mailto:GV_Khusainov2@tnnc.rosneft.ru)

*A.S. Kovalkova*, Leading Specialist, Tyumen Oil Research Center LLC

79/1, Osipenko Str., 625000, Tyumen, Russian Federation

E-mail: [AS\\_Kovalkova@tnnc.rosneft.ru](mailto:AS_Kovalkova@tnnc.rosneft.ru)

*Статья поступила в редакцию 22.09.2024*

*Принята к публикации 17.12.2024*

*Опубликована 30.12.2024*