

УДК 622 + 553.98

Статья / Article

© ПНИПУ / PNRPU, 2025

Оптимизация алгоритма поиска наиболее достоверных реализаций геологической модели**Д.В. Потапов¹, И.С. Путилов², Г.П. Хижняк¹, А.В. Шумилов³**¹Пермский национальный исследовательский политехнический университет (Российская Федерация, 614990, г. Пермь, Комсомольский пр., 29)²ЛУКОЙЛ-Инжиниринг (Российская Федерация, 614015, г. Пермь, ул. Пермская, 3а)³Пермский государственный национальный исследовательский университет (Российская Федерация, 614068, г. Пермь, ул. Букирева, 15)**Optimization of the Algorithm for Searching for the Most Reliable Implementations of a Geological Model****Daniil V. Potapov¹, Ivan S. Putilov², Grigoriy P. Khizhnyak¹, Aleksandr V. Shumilov³**¹Perm National Research Polytechnic University (29 Komsomolskiy av., Perm, 614990, Russian Federation)²LUKOIL-Engineering LLC (3a Permskaya st., Perm, 614015, Russian Federation)³Perm State National Research University (15 Bukireva st., Perm, 614068, Russian Federation)**Получена / Received: 20.08.2024. Принята / Accepted: 05.12.2024. Опубликовано / Published: 24.02.2025****Ключевые слова:**

геостатистика, 3D-геологическая модель, аллювиальные отложения, стохастическое моделирование, кросс-валидация, байесовская оптимизация, последовательное индикаторное моделирование, оценка неопределенности.

Одной из важнейших задач в нефтегазодобывающей отрасли является прогнозирование значений геологических параметров продуктивных пластов в межскважинном пространстве. Точность оценки эффективной нефтенасыщенной толщины или значений фильтрационно-емкостных свойств в местах расположения проектного фонда скважин напрямую влияет на эффективность разработки нефтегазовых активов и на экономические показатели.

Задача прогнозирования значений геологических параметров осложняется тем, что геологическая среда изучена скважинами фрагментарно, а источники информации о межскважинном пространстве, несмотря на непрерывный технологический прогресс, обладают ограниченной точностью. К тому же реальное геологическое строение в большинстве случаев значительно сложнее, чем наше представление о нем. Вертикальная и латеральная неоднородность продуктивных пластов и высокая степень изменчивости геологических свойств не позволяют эффективно использовать методы интерполяции.

В данной работе представлены результаты апробации авторской методологии, направленной на поиск наиболее достоверных реализаций трехмерной модели литологии.

Предложенный подход основан на использовании байесовской оптимизации для определения наиболее оптимальных значений рангов вариограмм по осям X и Y при моделировании трехмерного куба литологии. Средняя абсолютная ошибка прогноза суммарной эффективной толщины пласта, рассчитанная с использованием кросс-валидации, использована в качестве основной метрики, оценивающей надежность трехмерной модели литологии. Полученные результаты демонстрируют преимущества применения байесовской оптимизации относительно классического подхода поиска оптимальных параметров модели с перебором по сетке. Во-первых, примененный подход позволил получить трехмерную модель литологии с более высокой прогностической способностью. И во-вторых, авторская методология позволила значительно сократить необходимые для расчетов вычислительные ресурсы.

Keywords:

geostatistics, 3D geological model, alluvial deposits, stochastic modeling, cross-validation, Bayesian optimization, sequential indicator modeling, uncertainty assessment.

One of the most important tasks in the oil and gas industry is to predict the values of geological parameters of productive formations in the interwell space. The accuracy of estimating the effective oil-saturated thickness or the values of filtration and capacity properties at the locations of the project well stock directly affects the efficiency of oil and gas assets development and economic indicators.

The task of predicting the values of geological parameters is complicated by the fact that the geological environment has been studied by wells in fragments, and sources of information about the interwell space, despite continuous technological progress, have limited accuracy. In addition, the real geological structure in most cases is much more complex than our understanding of it. The vertical and lateral heterogeneity of productive formations and the high degree of geological properties variability do not allow the effective use of interpolation methods.

This paper presents the results of testing the author's methodology aimed at finding the most reliable implementations of a three-dimensional lithology model.

The proposed approach is based on the use of Bayesian optimization to determine the most optimal values of variogram ranges along the X and Y axes during the modeling of a three-dimensional lithology cube. The mean absolute error of the predicted total effective thickness of the reservoir, calculated using cross-validation, was employed as the primary metric to evaluate the reliability of the three-dimensional lithology model. The results demonstrate the advantages of applying Bayesian optimization compared to the classical grid search method for parameter optimization. Firstly, the proposed approach enabled the creation of a three-dimensional lithology model with higher predictive capability. Secondly, the developed methodology significantly reduced the computational resources required for the calculations.

© **Потапов Даниил Валерьевич** – аспирант (тел.: +007 (902) 638 71 94, e-mail: potapov9401@mail.ru). Контактное лицо для переписки.© **Путилов Иван Сергеевич** – доктор технических наук, профессор, профессор кафедры нефтегазового инжиниринга (тел.: +007 (952) 662 80 00, e-mail: ivan.putilov@pnn.lukoil.com).© **Хижняк Григорий Петрович** – доктор технических наук, доцент, профессор кафедры нефтегазовых технологий (тел.: +007 (905) 863 76 55, e-mail: xgp@mail.ru).© **Шумилов Александр Владимирович** – доктор технических наук, профессор, профессор кафедры геофизики (тел.: +007 951 951 11 22, e-mail: shum5011@gmail.com).© **Daniil V. Potapov** (ORCID: 0009-0003-1280-1681) – PhD student (tel.: +007 (902) 638 71 94, e-mail: potapov9401@mail.ru). The contact person for correspondence.© **Ivan S. Putilov** (Author ID in Scopus: 25723777700) – Doctor in Engineering, Professor, Professor at the Department of Petroleum Engineering (tel.: +007 (342) 233 58, e-mail: ivan.putilov@pnn.lukoil.com).© **Grigoriy P. Khizhnyak** (Author ID in Scopus: 36711848000; ORCID: 0000-0003-2138-7083) – Doctor in Engineering, Associate Professor, Professor at the Department of Oil and Gas Technologies (tel.: +007 (905) 863 76 55, e-mail: xgp@mail.ru).© **Aleksandr V. Shumilov** (Author ID in Scopus: 6507829582; ORCID: 0000-0002-0601-3123) – Doctor in Engineering, Professor, Professor at the Department of Geophysics (tel.: +007 951 951 11 22, e-mail: shum5011@gmail.com).

Просьба ссылаться на эту статью в русскоязычных источниках следующим образом:

Оптимизация алгоритма поиска наиболее достоверных реализаций геологической модели / Д.В. Потапов, И.С. Путилов, Г.П. Хижняк, А.В. Шумилов // Недропользование. – 2025. – Т.25, №1. – С. 1–8. DOI: 10.15593/2712-8008/2025.1.1

Please cite this article in English as:

Potapov D.V., Putilov I.S., Khizhnyak G.P., Shumilov A.V. Optimization of the algorithm for searching for the most reliable implementations of a geological model. *Perm Journal of Petroleum and Mining Engineering*, 2025, vol.25, no.1, pp. 1-8. DOI: 10.15593/2712-8008/2025.1.1

В начале 1960-х гг. возникла наука геостатистика, которая позволила выполнять не только пространственное моделирование параметров, но и пространственный анализ неопределенности [1–7]. В настоящее время при создании трехмерных геологических моделей широко используются такие методы моделирования, как последовательное гауссово моделирование (Sequential Gaussian Simulation, SGS) для непрерывных параметров и последовательное индикаторное моделирование (Sequential Indicator Simulation, SIS) для дискретных параметров [8–10]. Эти методы моделирования основаны на вариограммном анализе и позволяют сгенерировать множество равновероятных реализаций распределения геологических свойств.

Однако классические геостатистические методы имеют ряд недостатков, таких как чувствительность к выбору вариограммы и субъективизм при выполнении вариограммного анализа, низкую адаптивность к сложным реальным условиям, высокую вычислительную сложность и др. [11–14]. Поэтому перспективным направлением развития методов геостатистики является разработка гибридных моделей с использованием алгоритмов искусственного интеллекта, таких как машинное обучение, нейронные сети, генетические алгоритмы, нечеткая логика и др. [2–7, 10, 15].

При использовании геостатистических алгоритмов моделирования важно учитывать не только результаты вариограммного анализа, но и оценивать прогнозную способность каждой модели. В работах [16–20] предлагается несколько количественных критериев для оценки качества моделей трехмерного параметра литологии и выбора оптимальных параметров моделирования. Предложенные критерии позволяют оценивать прогнозную способность каждой реализации трехмерной модели литологии с выбором наиболее достоверных реализаций.

Расчет ансамбля реализаций в вышеуказанных работах основывался на теории планирования эксперимента. Авторы определили диапазон изменения параметров моделирования и шаг, с которым будет происходить изменение каждого параметра. Следовательно, в эксперимент включали полный набор возможных комбинаций параметров моделирования литологии и после проведения эксперимента, используя значения количественных критериев, отбирали наиболее достоверные реализации. Расчеты кубов литологии производились стохастическим алгоритмом с варьированием значений рангов вариограмм по осям X и Y [16–20].

Одним из трех предложенных критериев является критерий D_{skv} , рассчитываемый путем поскважинной кросс-валидации методом выколотой точки для каждой комбинации рангов вариограмм. Критерий необходим для оценки прогнозной способности модели и рассчитывается по формуле:

$$D_{skv} = \sum_{i=1}^n \frac{(H_{ef}^i - H_{ef}^m)}{n}, \quad (1)$$

где D_{skv} – отклонение от истинного значения эффективной толщины коллектора, м; H_{ef} – фактическое значение эффективных толщин коллектора в скважине, м; H_{ef}^m – модельное значение эффективных толщин коллектора, полученное после исключения данной скважины, м; n – количество скважин.

Основные геолого-физические характеристики объекта

Параметр	Общая толщина, м	Эффективная толщина, м	Средневзвешенное значение $K_{из}$, доли ед.	Коэффициент расчлененности в скв., шт.
Min	7,59	3,56	0,15	1
Mean	16,56	9,12	0,22	3
Max	33,59	22,55	0,25	8
Std	5,69	3,66	0,02	2

В машинном обучении описанный выше подход называется «поиск по сетке», или grid search, и также часто применяется с использованием кросс-валидации в качестве функции оценки достоверности каждой модели. Основным недостатком предложенного подхода является огромная вычислительная нагрузка при учете всех возможных комбинаций рангов вариограмм и использовании полной поскважинной кросс-валидации для расчета критерия D_{skv} . Количество расчетов трехмерного параметра литологии вычислялось как произведение количества комбинаций гиперпараметров и количества скважин. В некоторых случаях количество расчетов трехмерных параметров литологии составило более 10 000, а время расчета всего ансамбля – более суток.

Еще одним ограничением предложенного подхода является варьирование всего лишь двух параметров моделирования литологии: рангов вариограмм по осям X и Y . При переборе всех возможных комбинаций рангов вариограмм большинство моделей являются анизотропными, то есть с различными значениями рангов. При этом значение азимута всегда одно – 0° . Такое допущение обосновано вычислительными ограничениями, так как включение в эксперимент параметра азимута вариограммы многократно увеличивает количество реализаций.

Целью данной работы является разработка усовершенствованного алгоритма, позволяющего наиболее эффективно выполнять автоматизированный поиск наиболее достоверных реализаций геологической модели без необходимости рассчитывать полный ансамбль моделей.

Объект исследования

Объектом исследования является терригенный пласт аллювиального генезиса месторождения X , приуроченного к Волго-Уральской нефтегазоносной провинции (НПП). Основные геолого-физические характеристики объекта, определенные по данным интерпретации ГИС в 62 скважинах, представлены в табл. 1.

Аллювиальные отложения являются неоднородными как по латерали, так и по вертикали, что значительно осложняет задачу прогнозирования геологических параметров в межскважинном пространстве [21–24].

Площадь исследования покрыта съемкой 3D-сейсморазведки, результаты интерпретации которой использовались как для структурных построений, так и при литологическом моделировании.

Описание трехмерной геологической модели объекта

Так как исследуемый интервал месторождения X характеризуется согласным залеганием пластов, в данной работе использовался пропорциональный тип трехмерной сетки с латеральным размером ячейки 50×50 м. Среднее значение вертикального размера

Основные описательные статистики критерия D_{skv}^* по двум вариантам расчета

Вариант расчета	N набл.	Среднее	Медиана	Мин.	Макс.	Дисперсия	Ст. откл.	Коэф. вар.	Асимметрия	Экссесс
Вариант 1	100	1,093	1,083	0,923	1,360	0,0092	0,0957	8,758	0,6797	0,0652
Вариант 2	100	1,061	1,033	0,839	1,452	0,0188	0,1372	12,934	0,6853	-0,0128

ячейки – 0,26 м, общее количество активных ячеек составило более 3 млн. Такое детализированное разбиение сетки связано, во-первых, с наличием тонкослоистых прослоев алевролита в фации песков разлива, во-вторых, с необходимостью максимального соответствия усредненных скважинных данных исходным данным для более эффективных расчетов.

Моделирование трехмерных кубов литологии производилось с использованием геостатистического алгоритма SIS. В качестве трендов использовалась комбинация 1D-тренда – геостатистического распределения (ГСР) доли коллектора по каждому слою сетки, и 2D-тренда – карты песчаности. Карта песчаности получена путем деления прогнозной карты эффективных толщин на карту общих толщин пласта.

Прогнозная карта эффективных толщин рассчитывалась по данным динамического анализа сейсморазведки 3D-методом многовариантного прогноза коллекторов [25, 26].

Методика

Основой для разработки авторского алгоритма послужили описанные выше работы [16–20]. Идея данного исследования заключается в автоматическом подборе гиперпараметров с целью минимизировать ошибку без расчета всех возможных вариантов модели. Примером такого подхода может послужить метод градиентного спуска в нейронной сети [27, 28], при котором веса нейронов корректируются таким образом, чтобы ошибка прогноза стремилась к минимуму.

Разработку авторского алгоритма можно разделить на несколько этапов. Целью первого этапа было уменьшение количества расчетов при вычислении метрики достоверности модели. На втором этапе подбирались алгоритмы оптимизации, позволяющие автоматически менять гиперпараметры модели, в данном случае значения рангов вариограмм, таким образом, чтобы ошибка стремилась к минимальному значению.

Количественной метрикой для оценки достоверности каждой рассчитанной реализации трехмерной модели литологии послужил критерий D_{skv}^* (средняя абсолютная ошибка) рассчитываемого по формуле

$$D_{skv}^* = \sum_{i=1}^n \frac{|H_{ef} - H_{ef}^m|}{n}. \quad (2)$$

В отличие от описанного выше (1) критерия D_{skv} который при осреднении отрицательных и положительных значений ошибок может достигать значение близкое нулю, критерий D_{skv}^* не чувствителен к знаку ошибки и может служить основой для оптимизации путем поиска глобальных и локальных минимумов.

Кросс-валидация

Задача уменьшения количества расчетов при вычислении критерия качества D_{skv}^* была выполнена за счет использования более представительной «обучающей» выборки с меньшим количеством циклов «обучения».

Вместо кросс-валидации методом выколотой точки для расчета критерия D_{skv}^* применена кросс-валидация методом складного ножа (Jackknife) с разделением исходных скважинных данных на несколько равных по количеству и плотности покрытия площади выборок.

В данной работе исходные скважинные данные случайным образом разделены на пять равных по объему выборок. При каждом расчете куба литологии исключалось 20 % скважин с последующим вычислением отклонения модельной эффективной толщины от фактической для каждой исключенной скважины. Во время второго цикла при расчете куба литологии исключались следующие 20 % скважин. Таким образом, за пять циклов вычислялось отклонение модельной эффективной толщины от фактической для всех имеющихся скважин. Среднее абсолютное значение всех рассчитанных отклонений является критерием качества модели D_{skv}^* . Размер тестовой выборки может определяться пользователем, тем не менее 20 % является оптимальным значением во многих задачах, связанных с машинным обучением [29, 30].

С целью оценить эффективность предлагаемого метода кросс-валидации в данной работе был проведен эксперимент с расчетом ансамбля реализаций трехмерных кубов литологии по методике, предложенной в работах [16–20] (вариант 1), и по методике, описанной выше, с разделением скважинных данных на пять равных выборок (вариант 2).

В обоих вариантах расчета варьировались только значения рангов вариограмм по осям X и Y. Исходя из плотности и равномерности расположения скважин и размера исследуемого объекта, шаг изменения параметров составил 500 м, диапазон изменения от 500 до 5000 м. Таким образом, для расчетов было использовано 100 комбинаций рангов вариограмм. В первом случае прогнозная способность каждой модели оценивалась с использованием критерия D_{skv}^* путем реализации покскважинной кросс-валидации методом выколотой точки [16–20]. Так как количество скважин составило 62, то общий объем рассчитанных трехмерных кубов составил 6200 (по 62 для каждого набора рангов вариограмм). Во втором случае прогнозная способность моделей оценивалась вычислением критерия D_{skv}^* с использованием кросс-валидации методом складного ножа с разделением выборки на пять равных частей. Количество расчетов трехмерного куба литологии составило 500 (по пять расчетов для каждого набора рангов вариограмм). На рис. 1 представлены итоговые поверхности откликов критерия D_{skv}^* , рассчитанных с помощью кросс-валидации методом выколотой точки (а) и кросс-валидации методом складного ножа с разделением выборки на пять равных частей (б).

Визуально обе поверхности откликов обладают схожестью, тем не менее для более обоснованного сопоставления был выполнен сравнительный анализ двух подходов. В табл. 2 приведены основные описательные статистики по критерию D_{skv}^* , полученному в результате двух вариантов расчетов: вариант 1 – применение покскважинной кросс-валидации методом выколотой точки, вариант 2 – применение кросс-валидации методом складного ножа с пятью равными выборками.

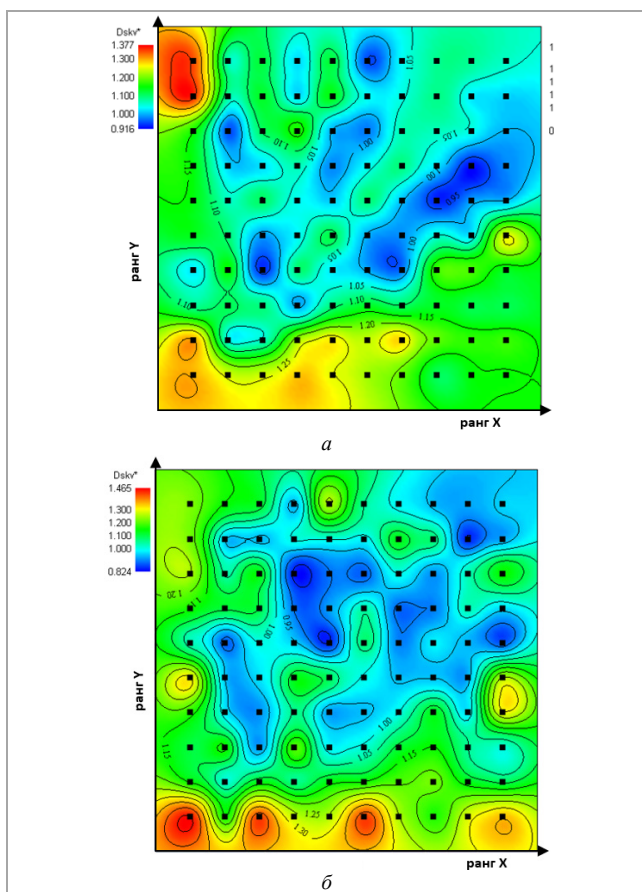


Рис. 1. Поверхности откликов, полученные с использованием кросс-валидации методом выколотой точки (а) и кросс-валидации методом складного ножа (б)




Рис. 2. Гистограммы распределения критерия D_{skv}^* , полученного с использованием кросс-валидации методом выколотой точки (а) и методом складного ножа (б)

Как видно в варианте 2, минимальное и среднее значения критерия D_{skv}^* несколько ниже, чем в варианте 1. При этом в варианте 2 незначительно выше максимальное значение критерия D_{skv}^* и дисперсия.

Для сравнения двух выборок необходимо определить, являются ли их распределения нормальными. Для этого были построены гистограммы и нормальные вероятностные графики по двум выборкам критерия D_{skv}^* (рис. 2, 3).

На гистограммах и нормальных вероятностных графиках видно, что распределения в обоих вариантах близки к нормальному, но в областях низких и высоких значений отклонение фактических частот от нормального распределения увеличивается. Расчет статистических критериев Шапиро – Уилка и Колмогорова – Смирнова также показал, что распределения параметра D_{skv}^* в обоих вариантах отлично от нормального. Тем не менее, так как отклонение от нормальности незначительное, для сравнения выборок использовались как параметрические, так и непараметрические критерии (табл. 3).

Полученные p -значения при расчете t -критерия и критерия Вилкоксона незначительно ниже уровня значимости 0,05. Результаты сравнения выборок неоднозначные и не позволяют утверждать о статистически значимых различиях между результатами применения двух различных методов кросс-валидации.

Для более обоснованных выводов необходимо провести регрессионный анализ для двух наборов критерия D_{skv}^* . Диаграмма рассеяния с линией регрессии представлена на рис. 4.

Уравнение регрессии:

$$D_{skv}2^* = 0,898 \cdot D_{skv}1^* + 0,0799, \quad (3)$$

где $D_{skv}1^*$ – критерий, рассчитанный кросс-валидацией методом выколотой точки; $D_{skv}2^*$ – критерий, рассчитанный методом складного ножа; коэффициент корреляции составил $r = 0,62$; коэффициент детерминации $r^2 = 0,39$; $p = 0,0001 < 0,05$.

Результат регрессионного анализа демонстрирует высокую степень линейной корреляции между двумя наборами критерия D_{skv}^* . Визуальное сходство поверхностей откликов также свидетельствует, что между двумя наборами критериев D_{skv}^* , рассчитанных с использованием разных методов кросс-валидации, существует статистически значимая связь.

Подводя итоги по выбору и обоснованию метода кросс-валидации, можно сделать следующие выводы:

- поверхности откликов визуально обладают схожестью, а между двумя наборами критерия D_{skv}^* существует статистически значимая связь, что выявлено при регрессионном анализе;

- несмотря на то, при использовании кросс-валидации методом складного ножа трехмерные модели литологии построены с использованием значительно меньшего количества скважинных данных, чем при использовании полной кросс-валидации методом выколотой точки, прогнозная способность таких моделей не меньше. Более того, среднее значение метрики точности D_{skv}^* даже несколько ниже в варианте 2;

- расчеты с использованием кросс-валидации методом складного ножа значительно менее затратны как по времени, так и по объему вычислений. Разница возрастает с увеличением количества скважин, в данной работе полный цикл расчетов с использованием кросс-валидации методом складного ножа оказался в 12,5 раз быстрее, чем расчеты с использованием кросс-валидации методом выколотой точки;

- одной из причин нецелесообразности применения поскважинной кросс-валидации методом выколотой точки является стационарный шум, свойственный большинству геостатистических алгоритмов [8]. В зависимости от последовательности вычислений, которая определяется случайным числом project seed, результат вычисления ошибки прогноза может быть различным [10, 31]. При использовании кросс-валидации методом складного ножа с исключением из построений группы скважин влияние непредсказуемости прогноза и стационарного шума минимизируется.

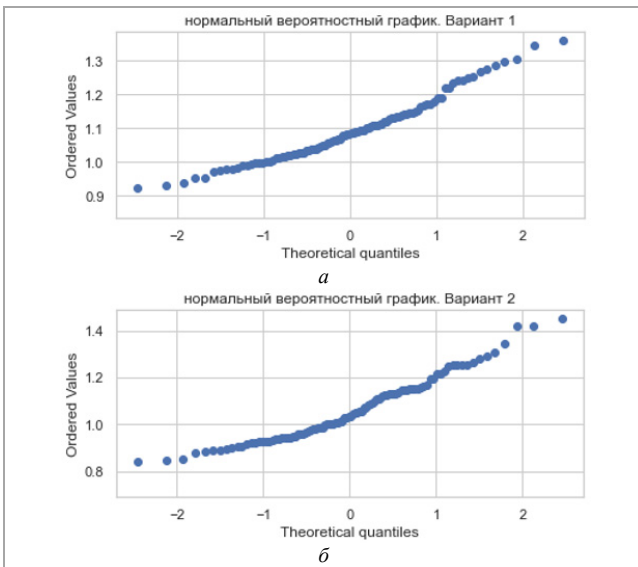


Рис. 3. Нормальные вероятностные графики для критерия D_{skv}^* , полученного с использованием кросс-валидации методом выколотой точки (а) и методом складного ножа (б)

Таблица 3

Результат расчета статистических критериев

Статистический критерий	Значение критерия	$p < 0,05$
Шапиро – Уилка	0,952	0,001
Колмогорова – Смирнова	0,799	0,0001
F-критерий	2,94	0,0041
Критерий Вилкоксона	2,91	0,0036

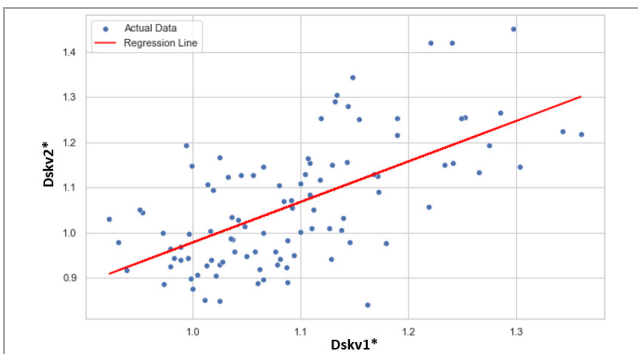


Рис. 4. Зависимость между критерием D_{skv1}^* , рассчитанным кросс-валидацией методом выколотой точки, и критерием D_{skv2}^* , рассчитанным кросс-валидацией методом складного ножа



Рис. 5. Блок-схема алгоритма поиска оптимальных значений гиперпараметров

Таким образом, можно заключить, что кросс-валидация методом складного ножа является не менее эффективной с точки зрения оценки прогнозной способности моделей литологии и более эффективной с точки зрения скорости вычислений. В следующем этапе исследований, целью которого является апробация алгоритма автоматического подбора значений рангов вариограмм, будет использоваться кросс-валидация методом складного ножа с разделением набора скважин на пять равных выборок.

Байесовская оптимизация

Оптимальными значениями гиперпараметров модели являются такие значения гиперпараметров, в данной случае рангов вариограмм по осям X и Y , при которых ошибка прогноза (метрика D_{skv}^*) стремится к нулю. Задача поиска глобального минимума осложняется тем, что стохастические геостатистические алгоритмы, такие как Sequential Indicator Simulation, Sequential Gaussian Simulation и др., подвержены влиянию стационарного шума. Это приводит к тому, что значение ошибки прогноза будет зависеть не только от настроек модели, но и в некоторой степени от случайной составляющей (random path) [10].

В процессе поиска подходящего алгоритма было протестировано несколько популярных методов оптимизации. Тем не менее относительно эффективным оказался лишь алгоритм, основанный на байесовской оптимизации.

Байесовская оптимизация позволяет находить экстремумы сложных функций, в том числе функций, подверженных влиянию случайного шума. В основе этого метода лежит представление о целевой функции как о реализации гауссовского процесса – это означает, что значения функции в разных точках связаны между собой вероятностным образом. На каждой итерации алгоритма строится модель гауссовского процесса, учитывающая все полученные ранее результаты. Затем с использованием так называемой функции приобретения выбирается следующий набор параметров модели. Функция приобретения в начале процесса разбивает все пространство поиска на несколько крупных гиперкубов. Для каждого гиперкуба вычисляется метрика качества, в нашем случае это средняя абсолютная ошибка D_{skv}^* . На основе такой оценки выбирается гиперкуб с наименьшим значением ошибки. Затем выбранный гиперкуб разбивается на более мелкие, для каждого из которых снова вычисляется метрика качества. Такой подход позволяет сосредоточиться на наиболее перспективных областях пространства поиска и ускорить процесс нахождения оптимума [32–37].

Схема процесса оптимизации представлена на рис. 5.

Первым этапом выполняется инициализация, заключающаяся в определении целевой функции, диапазона изменения гиперпараметров функции и критерия остановки оптимизации. В нашем случае целевой функцией является расчет пяти итераций трехмерного параметра литологии с вычислением средней абсолютной ошибки по всем скважинам (критерий D_{skv}^*) путем кросс-валидации методом складного ножа. Гиперпараметрами являются ранги вариограмм по осям X и Y . Диапазон изменения рангов вариограмм от 500 до 5000 м. Критерий остановки в нашем случае – завершение расчета 100 итераций.

После инициализации и выбора значений рангов вариограмм рассчитывается целевая функция. В первых итерациях оптимизации значения рангов вариограмм по осям X и Y выбирается случайным образом. Расчет целевой функции заключается в генерации трехмерных параметров литологии методом SIS с оценкой средней абсолютной ошибки прогноза D_{skv}^* путем кросс-валидации методом складного ножа.

Затем выполняется сохранение результата расчета целевой функции в базе данных и обновление модели аппроксимации. С помощью функции приобретения, принципы расчета которой описаны выше, определяется следующий набор гиперпараметров. Процесс оптимизации повторяется заданное количество циклов либо до тех пор, пока не выполнятся заданные пользователем условия.

Ниже представлены поверхности откликов, рассчитанные ранее путем перебора рангов вариограмм по сетке с использованием кросс-валидации методом складного ножа. Для демонстрации эффективности процесса оптимизации на поверхности откликов нанесены результаты расчета параметра D_{skv}^* с использованием байесовской оптимизации (рис. 6).

Низкие значения параметра D_{skv}^* обозначаются синим цветом, высокие – красным, а средние значения обозначаются зеленым цветом. На рис. 6 можно наблюдать, как результаты расчета байесовской оптимизации стремятся к локальным минимумам на поверхности отклика параметра D_{skv}^* , при этом локальные максимумы функция «избегает». При этом также можно утверждать, что пространство поиска исследовано относительно равномерно. Равномерность достигается за счет применения разделения пространства поиска на гиперкубы с вычислением метрики качества для каждого.

В большинстве случаев на терригенных пластах аллювиального генезиса Волго-Уральской НГП анизотропия свойств не ярко выражена, и соотношение значений рангов вариограмм обычно не более чем 1:2. Следовательно, акцент алгоритма оптимизации на проработку областей поиска, в которых значения рангов по осям X и Y не различаются более чем в два раза, также свидетельствует о корректности применения технологии байесовской оптимизации для задачи геологического моделирования.

Результаты

В данной работе был выполнен ряд расчетов трехмерного параметра литологии с использованием стохастического алгоритма Sequential Indicator Simulation. При расчете кубов литологии варьировалось два параметра – ранги вариограмм по оси X и Y . Для оценки прогнозной способности каждой модели рассчитывалось значение средней абсолютной ошибки D_{skv}^* . Причем экспериментально доказано, что кросс-валидация методом складного ножа является более оптимальной, чем кросс-валидация методом выколотой точки. Изначально для оценки прогнозной способности каждой модели использовался подход поиска по сетке (grid search) с построением поверхности отклика, позволяющей визуально определить, при каких значениях гиперпараметров модель является наиболее точной.

Следующим шагом рассчитывался набор трехмерных параметров литологии, только вместо поиска по сетке для варьирования гиперпараметров использовался алгоритм, основанный на байесовской оптимизации. В обоих случаях прогнозная способность моделей определялась как средняя абсолютная ошибка прогноза (критерий D_{skv}^*) с использованием кросс-валидации методом складного ножа.

В результате при использовании подхода поиска по сетке минимальное значение критерия D_{skv}^* составило 0,839 м, значение рангов по осям X и Y 2000 и 4000 м соответственно. В случае применения байесовской оптимизации значение критерия D_{skv}^* наиболее достоверной модели составило 0,803 м, что на 4,3 % меньше, чем при переборе гиперпараметров по сетке. Значения рангов вариограмм наиболее достоверной модели по осям X и Y составило 3895 и 3547 м соответственно.

Таким образом, успешно применен алгоритм байесовской оптимизации для поиска наиболее оптимальных значений рангов вариограмм по осям X и Y при моделировании трехмерного параметра

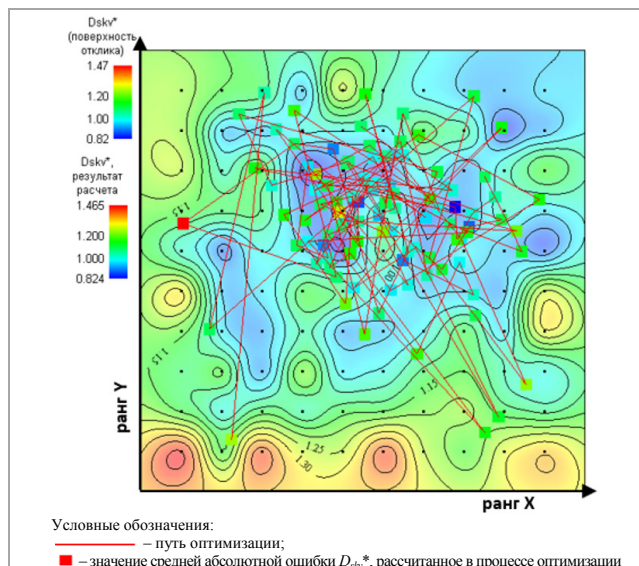


Рис. 6. Поверхность отклика параметра D_{skv}^* с результатами байесовской оптимизации

литологии. Байесовская оптимизация позволила более детально изучить ту область поиска, в которой значения ошибки модели минимальные, и более точно подобрать параметры модели, в то время как поиск по сетке из-за фиксированного шага изменения гиперпараметров «пропустил» наиболее подходящие значения гиперпараметров.

Заключение

Применение современных вычислительных алгоритмов наряду с классическими инструментами геостатистики позволяет значительно повысить надежность геологического моделирования и адаптировать его для решения широкого спектра нетривиальных задач, таких как прогноз свойств в межскважинном пространстве и в скважинах, прогноз параметров разработки месторождений и экономических показателей [38–46]. Выполнение задач прогноза геологических параметров часто осложнено тем, что геологическая среда обладает сложным и непредсказуемым строением, моделирование в таких условиях сопряжено с множеством трудностей.

В данной работе в качестве объекта моделирования выбран терригенный пласт аллювиального генезиса одного из месторождений Волго-Уральской НГП. На примере моделирования трехмерного параметра литологии продемонстрированы результаты применения байесовской оптимизации для задачи поиска наиболее достоверных моделей. Ключевое преимущество байесовской оптимизации заключается в ее пригодности для функций черного ящика и функций, подверженных влиянию шума.

Успешная оптимизация процесса поиска наиболее достоверных моделей литологии позволит в дальнейшем усложнять модель путем добавления дополнительных гиперпараметров и метрик достоверности модели.

Авторская методология позволяет обойти ряд ограничений традиционного применения геостатистических инструментов и более обоснованно спрогнозировать распределение коллекторов в межскважинном пространстве, что особенно актуально для задачи поиска объектов для уплотняющего бурения на месторождениях.

Библиографический список

1. Потапов, Д.В. Анализ геологических рисков на этапе оценки запасов с целью повышения эффективности освоения актива / Д.В. Потапов, Е.И. Ефремова // Нефтегазовая геология. Теория и практика. – 2023. – Т. 18, № 1. – С. 13–29. DOI: 10.17353/2070-5379/2_2023
2. Прямой нейросетевой прогноз коллекторских свойств пласта по данным сейсморазведки на примере клиноформных отложений Западной Сибири / И.И. Приезжев [и др.] // ПРОНЕФТЬ. Профессионально о нефти. – 2023. – Т. 8, № 2. – С. 28–39. DOI: 10.51890/2587-7399-2023-8-2-28-39
3. Егоров, Д.В. Анализ применимости алгоритмов машинного обучения для задач интерполяции и прогноза геологических свойств в межскважинном пространстве / Д.В. Егоров, Б.В. Белозеров // ПРОНЕФТЬ. Профессионально о нефти. – 2022. – № 4. – С. 13–16. DOI: 10.24887/2587-7399-2018-4-13-16
4. Платов, Б.В. Оценка толщины маломощных пластов при помощи данных сейсморазведки на примере тульско-бобриковских отложений Республики Татарстан / Б.В. Платов, Р.И. Хайрутдинова, А.И. Кадиров // Известия высших учебных заведений. Геология и разведка. – 2021. – Т. 63, № 4. – С. 80–87. DOI: 10.32454/0016-7762-2020-63-4-80-87
5. Галкин, С.В. Методология учета геологических рисков на этапе поисков и разведки нефтяных месторождений / С.В. Галкин // Недропользование. – 2012. – № 4. – С. 23–32.
6. Демьянов, В.В. Геостатистика: теория и практика / В.В. Демьянов, Е.А. Савельева; под ред. Р. В. Арутюняна; Ин-т проблем безопасного развития атомной энергетики РАН. – М.: Наука, 2010. – 327 с.
7. Матерон, Ж. Основы прикладной геостатистики / пер. с фр. Ю.В. Рошина; под ред. и с предисл. д-ра геол.-мин. наук Д.Я. Суражского и канд. техн. наук А.М. Марголина; послесл. канд. техн. наук А.М. Марголина. – М.: РГБ, 2008. – 408 с.
8. Emery, X. Properties and limitations of sequential indicator simulation / X. Emery // Stochastic Environmental Research and Risk Assessment. – 2004. – Vol. 18. – P. 414–424. DOI: 10.1007/s00477-004-0213-5
9. Deutsch, C.V. A sequential indicator simulation program for categorical variables with point and block data: BlockSIS / C.V. Deutsch // Computers & Geosciences. – 2006. – Vol. 32, no. 10. – P. 1669–1681. DOI: 10.1016/j.cageo.2006.03.005
10. Juang, K.W. Using sequential indicator simulation to assess the uncertainty of delineating heavy-metal contaminated soils / K.W. Juang, Y.S. Chen, D.Y. Lee // Environmental Pollution. – 2004. – Vol. 127, no. 2. – P. 229–238. DOI: 10.1016/j.envpol.2003.07.001
11. Steel, M.F.J. Non-Gaussian and nonparametric models for continuous spatial data / M.F.J. Steel, M. Fuentes // Handbook of Spatial Statistics. – 2010. – P. 149–167. DOI: 10.1201/9781420072884-c11
12. Journel, A.J. Mining geostatistics / A.J. Journel, C.J. Huijbregts. – London: Academic Press, 1978. – 600 p.
13. Matheron, G. Principles of geostatistics / G. Matheron // Economic geology. – 1963. – Vol. 58, no. 8. – P. 1246–1266. DOI: 10.2113/gsecongeo.58.8.1246
14. Pyrcz, M.J. Geostatistical reservoir modeling / M.J. Pyrcz, C.V. Deutsch. – USA: Oxford University Press, 2014. – 448 p.
15. Tuia, D. Advanced Mapping of Environmental Data: Geostatistics / D. Tuia, M. Kanevski // Machine Learning and Bayesian Maximum Entropy. – London: John Wiley & Sons. – 2008. – 352 p.
16. Потехин, Д.В. Оптимизация технологии многовариантного трехмерного геологического моделирования залежей нефти и газа : дис. ... канд. техн. наук : 25.00.12 / Денис Владимирович Потехин. – Пермь, 2014. – 151 с.
17. Потехин, Д.В. Количественное обоснование параметров многовариантного моделирования для повышения достоверности трехмерных геологических моделей нефтяных месторождений / Д.В. Потехин, И.С. Путилов // Территория Нефтегаз. – 2014. – № 2. – С. 18–21.
18. Путилов, И.С. Многовариантное 3D-моделирование с контролем качества реализаций для повышения достоверности геологических моделей / И.С. Путилов, Д.В. Потехин, В.И. Галкин // Геология, геофизика и разработка нефтяных и газовых месторождений. – 2015. – № 10. – С. 17–20.
19. Потехин, Д.В. Повышение достоверности геологических моделей залежей нефти и газа на основе усовершенствованной технологии многовариантного трехмерного моделирования / Д.В. Потехин, И.С. Путилов, В.И. Галкин // Нефтяное хозяйство. – 2014. – № 6. – С. 16–19.
20. Потехин, Д.В. Построение 3D геологических моделей нефтяных залежей на основе метода вероятностных множественных реализаций / Д.В. Потехин // Геология, геофизика и разработка нефтяных и газовых месторождений. – 2023. – № 7. – С. 12–18.
21. Построение детальной литолого-фациальной трехмерной модели на основе комплексирования геолого-геофизических данных на примере бобриковских отложений Батыйбайского месторождения Пермского края / Д.В. Потапов, Н.О. Азанова, А.Е. Подосенов, С.В. Ладейщиков // Нефтепромысловое дело. – 2022. – № 11 (647). – С. 5–14. DOI: 10.33285/0207-2351-2022-11(647)-5-14
22. Прогнозирование фаций терригенных отложений на основе высокоинформативных сейсмических данных 3D и машинного обучения / С.В. Ладейщиков [и др.] // Геофизика. – 2018. – № 5. – С. 31–37.
23. Прогноз геологического строения на основе многовариантной модели Ростовицкого месторождения / А.Е. Подосенов [и др.] // Нефтепромысловое дело. – 2021. – № 11 (635). – С. 5. DOI: 10.33285/0207-2351-2021-11(635)-5-13
24. Ладейщиков, С.В. Опыт выполнения комплексных прогнозов фаций на основе высокоинформативных сейсмических данных для задач геолого-гидродинамического моделирования / С.В. Ладейщиков, И.С. Путилов // Геология, геофизика и разработка нефтяных и газовых месторождений. – 2019. – № 3. – С. 66–73.
25. Путилов, И.С. Многовариантный прогноз коллекторов по данным 3D-сейсморазведки / И.С. Путилов // Технологии сейсморазведки. – 2013. – № 1. – С. 59.
26. Путилов, И.С. Разработка новой технологии многовариантного прогноза нефтегазоносности по сейсмическим данным / И.С. Путилов // Геология, геофизика и разработка нефтяных и газовых месторождений. – 2014. – № 4. – С. 47–54.
27. Gradient-based learning applied to document recognition / Y. LeCun [et al.] // Proceedings of the IEEE. – 1998. – Vol. 86, no. 11. – P. 2278–2324. DOI: 10.1109/5.726791
28. Efficient backprop / Y. LeCun [et al.] // Neural networks: Tricks of the trade. – Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. – P. 9–50. DOI: 10.1007/978-3-642-35289-8_3
29. Interpretability in healthcare: A comparative study of local machine learning interpretability techniques / R. ElShawi, Y. Sherif, M. Al-Mallah, S. Sakr // Computational Intelligence. – 2021. – Vol. 37, no. 4. – P. 1633–1650. DOI: 10.1111/coin.12410
30. Применение кросс-валидации при выборе вариограммы для моделирования куба пористости геологической 3D-модели / Ш.Р. Исламов, Л.Р. Сагирова, И.И. Боков, Г.В. Шелухов // Территория «Нефтегаз». – 2023. – № 11–12. – С. 14–23.
31. Soares, A. Sequential indicator simulation with correction for local probabilities / A. Soares // Mathematical geology. – 1998. – Vol. 30, no. 6. – P. 761–765. DOI: 10.1023/A:1022451504120
32. Feurer, M. Hyperparameter optimization / M. Feurer, F. Hutter // Automated machine learning: Methods, systems, challenges. – 2019. – P. 3–33. DOI: 10.1007/978-3-030-05318-5_1
33. Frazier, P.I. Bayesian optimization / P.I. Frazier // Recent advances in optimization and modeling of contemporary problems. – Informs, 2018. – P. 255–278. DOI: 10.1287/educ.2018.0188
34. Snoek, J. Practical bayesian optimization of machine learning algorithms / J. Snoek, H. Larochelle, R.P. Adams // Advances in neural information processing systems. – 2012. – Vol. 25. – P. 1601–1610. DOI: 10.48550/arXiv.1206.2944
35. Jafarsteh, B. Objective functions from Bayesian optimization to locate additional drillholes / B. Jafarsteh, A. Suárez // Computers & Geosciences. – 2021. – Vol. 147. – P. 104674. DOI: 10.1016/j.cageo.2020.104674
36. Nowak W., De Barros F.P.J., Rubin Y. Bayesian geostatistical design: Task-driven optimal site investigation when the geostatistical model is uncertain / W. Nowak, F.P.J. De Barros, Y. Rubin // Water Resources Research. – 2010. – Vol. 46, no. 3. – P. 463–481. DOI: 10.1029/2009WR008312
37. Carpenter, C. Combined Geostatistics and Bayesian Updating Optimize Drilling in Shale-Gas Plays / C. Carpenter // Journal of Petroleum Technology. – 2014. – Vol. 66, no. 10. – P. 179–184. DOI: 10.2118/1014-0179-JPT
38. Kim, J. Lithofacies classification integrating conventional approaches and machine learning technique / J. Kim // Journal of Natural Gas Science and Engineering. – 2022. – Vol. 100. – P. 104500. DOI: 10.1016/j.jngse.2022.104500
39. Al-Mudhafar, W.J. Integrating well log interpretations for lithofacies classification and permeability modeling through advanced machine learning algorithms / W.J. Al-Mudhafar // Journal of Petroleum Exploration and Production Technology. – 2017. – Vol. 7, no. 4. – P. 1023–1033. DOI: 10.1007/s13202-017-0360-0
40. Antariksa, G. Performance evaluation of machine learning-based classification with rock-physics analysis of geological lithofacies in Tarakan Basin, Indonesia / G. Antariksa, R. Muammar, J. Lee // Journal of Petroleum Science and Engineering. – 2022. – Vol. 208. – P. 109250. DOI: 10.1016/j.petrol.2021.109250
41. Stochastic reconstruction of fracture network pattern using spatial point processes / M. Shakiba [et al.] // Geoenergy Science and Engineering. – 2024. – Vol. 236. – P. 212741. DOI: 10.1016/j.geoen.2024.212741
42. Özbayrak, F. Spatial bagging to integrate spatial correlation into ensemble machine learning / F. Özbayrak, J.T. Foster, M.J. Pyrcz // Computers & Geosciences. – 2024. – Vol. 186. – P. 105558. DOI: 10.1016/j.cageo.2024.105558
43. Pyrcz, M.J. Data analytics and geostatistical workflows for modeling uncertainty in unconventional reservoirs / M.J. Pyrcz // Bulletin of Canadian Petroleum Geology. – 2019. – Vol. 67, no. 4. – P. 273–282. DOI: 10.35767/gscpgbull.67.4.273
44. Pyrcz M.J. Transforming data to a gaussian distribution / M.J. Pyrcz, C.V. Deutsch, J.L. Deutsch // Geostatistics Lessons. – 2018. – P. 27–38.
45. Automatic well log analysis across priobskoe field using machine learning methods / B. Belozеров [et al.] // SPE Russian Petroleum Technology Conference. – SPE, 2018. – P. D013S002R011. DOI: 10.2118/191604-18RPTC-MS
46. Image processing and machine learning approaches for petrographic thin section analysis / S. Budenny [et al.] // SPE Russian Petroleum Technology Conference. – SPE, 2017. – P. D023S014R005. DOI: 10.2118/187885-MS

References

1. Potapov D.V., Efremova E.I. Analiz geologicheskikh riskov na etape otsenki zapasov s tsel'iu povysheniia effektivnosti osvoeniia aktiva [Analysis of geological risks at the stage of reserves assessment in order to increase the asset development efficiency]. *Neftgazovaya geologiya. Teoriya i praktika*, 2023, vol. 18, no. 1, pp. 13-29. DOI: 10.17353/2070-5379/2_2023
2. Prizhev I.I. et al. Priamoi neirosetevoi prognoz kolektorskikh svoystv plasta po dannym seismorazvedki na primere klinofornnykh otlozhenii Zapadnoi Sibiri [Neural network prediction of reservoir properties of the reservoir according to seismic data on the example of clinoforn deposits of Western Siberia]. *PRONEFT. Professionalno o nefi*, 2023, vol. 8, no. 2, pp. 28-39. DOI: 10.51890/2587-7399-2023-8-2-28-39

3. Egorov D.V., Belozеров B.V. Analiz primenimosti algoritmov mashinnogo obucheniia dlia zadach interpolatsii i prognoza geologicheskikh svoystv v mezhskvazhinno prostranstve [Analysis of machine learning algorithms applicability for tasks of interpolation and geological properties forecasting within interwell space]. *PRONEFT. Professional'no o nef'ti*, 2022, no. 4, pp. 13-16. DOI: 10.24887/2587-7399-2018-4-13-16
4. Platov B.V., Khairutdinova R.I., Kadirov A.I. Otsenka tolshchiny malomoshchnykh plastov pri pomoshchi dannykh seismorazvedki na primere tul'sko-bobrikovskikh otlozhenii Respubliki Tatarstan [Evaluating the thickness of thin-bed seams using seismic data on the example of the Tula-Bobrikovian sediments in the Republic of Tatarstan]. *Izvestiia vysshikh uchebnykh zavedenii. Geologiya i razvedka*, 2021, vol. 63, no. 4, pp. 80-87. DOI: 10.32454/0016-7762-2020-63-4-80-87
5. Galkin S.V. Metodologiya ucheta geologicheskikh riskov na etape poiskov i razvedki nef'tiannykh mestorozhdenii [Accounting methods of geological risks on the stage of oil fields exploration]. *Nedropol'zovanie*, 2012, no. 4, pp. 23-32.
6. Dem'ianov V.V., Sav'el'eva E.A. Geostatistika: teoriia i praktika [Geostatistics: Theory and Practice]. Ed. R.V. Arutiunian, Institut problem bezopasnosti razvitiia atomnoi energetiki Rossiiskoi akademii nauk. Moscow: Nauka, 2010, 327 p.
7. Materon Zh. Osnovy prikladnoi geostatistiki [Fundamentals of Applied Geostatistics]. Eds. D.Ia. Surazhskii, A.M. Margolin. Moscow: Rossiiskaia gosudarstvennaia biblioteka, 2008, 408 p.
8. Emery X. Properties and limitations of sequential indicator simulation. *Stochastic Environmental Research and Risk Assessment*, 2004, vol. 18, pp. 414-424. DOI: 10.1007/s00477-004-0213-5
9. Deutsch C.V. A sequential indicator simulation program for categorical variables with point and block data: BlockSIS. *Computers & Geosciences*, 2006, vol. 32, no. 10, pp. 1669-1681. DOI: 10.1016/j.cageo.2006.03.005
10. Juang K.W., Chen Y.S., Lee D.Y. Using sequential indicator simulation to assess the uncertainty of delineating heavy-metal contaminated soils. *Environmental Pollution*, 2004, Vol. 127, no. 2, pp. 229-238. DOI: 10.1016/j.envpol.2003.07.001
11. Steel M.F.J., Fuentes M. Non-Gaussian and nonparametric models for continuous spatial data. *Handbook of Spatial Statistics*, 2010, pp. 149-167. DOI: 10.1201/9781420072884-c11
12. Journel A.J., Huijbregts C.J. Mining geostatistics. London: Academic Press, 1978, 600 p.
13. Matheron G. Principles of geostatistics. *Economic geology*, 1963, vol. 58, no. 8, pp. 1246-1266. DOI: 10.2113/gsecongeo.58.8.1246
14. Pyrcz M.J., Deutsch C.V. Geostatistical reservoir modeling. USA: Oxford University Press, 2014, 448 p.
15. Tuia D., Kanevski M. Advanced Mapping of Environmental Data: Geostatistics. *Machine Learning and Bayesian Maximum Entropy*. London: John Wiley & Sons, 2008, 352 p.
16. Potekhin D.V. Optimizatsiia tekhnologii mnogovariantnogo trekhmernogo geologicheskogo modelirovaniia zalezhei nef'ti i gaza [Optimization of technology for multivariate three-dimensional geological modeling of oil and gas deposits]. Ph D. thesis. Perm', 2014, 151 p.
17. Potekhin D.V., Putilov I.S. Kolichestvennoe obosnovanie parametrov mnogovariantnogo modelirovaniia dlia povysheniia dostovernosti trekhmernykh geologicheskikh modelei nef'tiannykh mestorozhdenii [Selection optimal settings of multivariate modeling to improve the reliability of 3D geological models of oil fields]. *Territoria Neftegaz*, 2014, no. 2, pp. 18-21.
18. Putilov I.S., Potekhin D.V., Galkin V.I. Mnogovariantnoe 3D-modelirovanie s kontrolem kachestva realizatsii dlia povysheniia dostovernosti geologicheskikh modelei [Multiple 3D modelling with quality surveillance of realizations to increase reliability of geological models]. *Geologiya, geofizika i razrabotka nef'tiannykh i gazovykh mestorozhdenii*, 2015, no. 10, pp. 17-20.
19. Potekhin D.V., Putilov I.S., Galkin V.I. Povyshenie dostovernosti geologicheskikh modelei zalezhei nef'ti i gaza na osnove uovershenstvovannoi tekhnologii mnogovariantnogo trekhmernogo modelirovaniia [Improve the reliability of geological models of oil fields on basis of optimized technological settings multivariate 3D modeling]. *Nef'tianoe khoziaistvo*, 2014, no. 6, pp. 16-19.
20. Potekhin D.V. Postroenie 3D geologicheskikh modelei nef'tiannykh zalezhei na osnove metoda veroiatnostnykh mnozhestvennykh realizatsii [Postroenie 3D geologicheskikh modelei nef'tiannykh zalezhei na osnove metoda veroiatnostnykh mnozhestvennykh realizatsii]. *Geologiya, geofizika i razrabotka nef'tiannykh i gazovykh mestorozhdenii*, 2023, no. 7, pp. 12-18.
21. Potapov D.V., Azanova N.O., Podosenov A.E., Ladeishchikov S.V. [Postroenie detal'noi litologo-fatsial'noi trekhmernoi modeli na osnove kompleksirovaniia geologo-geofizicheskikh dannykh na primere bobrikovskikh otlozhenii Batyrbaiskogo mestorozhdeniia Permskogo kraia [Construction of a detailed three-dimensional lithological-facial model based on the geological and geophysical data integration on the example of the Bobrikovsky deposits of the Batyrbayskoe field in the Perm region]. *Nef'tepromyslovoe delo*, 2022, no. 11 (647), pp. 5-14. DOI: 10.33285/0207-2351-2022-11(647)-5-14
22. Ladeishchikov S.V. et al. Prognozirovanie fatsii terrigenykh otlozhenii na osnove vysokoinformativnykh seismicheskikh dannykh 3D i mashinnogo obucheniia [Forecast facies of terrigenous deposits based on highly informed seismic 3D and machine learning]. *Geofizika*, 2018, no. 5, pp. 31-37.
23. Podosenov A.E. et al. Prognoz geologicheskogo stroeniia na osnove mnogovariantnoi modeli Rostovitskogo mestorozhdeniia [Forecast of the geological structure based on the multivariate model of the Rostovitskoe oil field]. *Nef'tepromyslovoe delo*, 2021, no. 11 (635), 5 p. DOI: 10.33285/0207-2351-2021-11(635)-5-13
24. Ladeishchikov S.V., Putilov I.S. Opyt vypolneniia kompleksnykh prognozov fatsii na osnove vysokoinformativnykh seismicheskikh dannykh dlia zadach geologo-gidrodinamicheskogo modelirovaniia [Experience in performing complex facies forecasts based on highly informative seismic data for geological and hydrodynamic modeling tasks]. *Geologiya, geofizika i razrabotka nef'tiannykh i gazovykh mestorozhdenii*, 2019, no. 3, pp. 66-73.
25. Putilov I.S. Mnogovariantnyi prognoz kollektorov po dannym 3D-seismorazvedki [Multivariate reservoir prediction from 3D seismic data]. *Tekhnologii seismorazvedki*, 2013, no. 1, 59 p.
26. Putilov I.S. Razrabotka novoi tekhnologii mnogovariantnogo prognoza neftegazonosnosti po seismicheskim dannym [Development of the new technology of multivariate prediction of oil and gas content by seismic data]. *Geologiya, geofizika i razrabotka nef'tiannykh i gazovykh mestorozhdenii*, 2014, no. 4, pp. 47-54.
27. LeCun Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 1998, vol. 86, no. 11, pp. 2278-2324. DOI: 10.1109/5.726791
28. LeCun Y. et al. Efficient backprop. *Neural networks: Tricks of the trade*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 9-50. DOI: 10.1007/978-3-642-35289-8_3
29. ElShawi R., Sherif Y., Al-Mallah M., Sakr S. Interpretability in healthcare: A comparative study of local machine learning interpretability techniques. *Computational Intelligence*, 2021, vol. 37, no. 4, pp. 1633-1650. DOI: 10.1111/coin.12410
30. Islamov Sh.R., Sagirova L.R., Bokov I.I., Shelukhov G.V. Primenenie kross-validatsii pri vybere variogrammy dlia modelirovaniia kuba poristosti geologicheskoi 3D-modelei [Application of Cross-Validation in Selecting the Variogram for Modeling the Porosity Cube of a 3D Geological Model]. *Territoria "Neftegaz"*, 2023, no. 11-12, pp. 14-23.
31. Soares A. Sequential indicator simulation with correction for local probabilities. *Mathematical geology*, 1998, vol. 30, no. 6, pp. 761-765. DOI: 10.1023/A:1022451504120
32. Feurer M., Hutter F. Hyperparameter optimization. *Automated machine learning: Methods, systems, challenges*, 2019, pp. 3-33. DOI: 10.1007/978-3-030-05318-5_1
33. Frazier P.I. Bayesian optimization. *Recent advances in optimization and modeling of contemporary problems*, 2018, pp. 255-278. DOI: 10.1287/educ.2018.0188
34. Snoek J., Larochelle H., Adams R.P. Practical bayesian optimization of machine learning algorithms. *Advances in neural information processing systems*, 2012, vol. 25, pp. 1601-1610. DOI: 10.48550/arXiv.1206.2944
35. Jafrasteh B., Suárez A. Objective functions from Bayesian optimization to locate additional drillholes. *Computers & Geosciences*, 2021, vol. 147, 104674 p. DOI: 10.1016/j.cageo.2020.104674
36. Nowak W., De Barros F.P.J., Rubin Y. Bayesian geostatistical design: Task-driven optimal site investigation when the geostatistical model is uncertain. *Water Resources Research*, 2010, vol. 46, no. 3, pp. 463-481. DOI: 10.1029/2009WR008312
37. Carpenter C. Combined Geostatistics and Bayesian Updating Optimize Drilling in Shale-Gas Plays. *Journal of Petroleum Technology*, 2014, vol. 66, no. 10, pp. 179-184. DOI: 10.2118/1014-0179-JPT
38. Kim J. Lithofacies classification integrating conventional approaches and machine learning technique. *Journal of Natural Gas Science and Engineering*, 2022, vol. 100, 104500 p. DOI: 10.1016/j.jngse.2022.104500
39. Al-Mudhafar W.J. Integrating well log interpretations for lithofacies classification and permeability modeling through advanced machine learning algorithms. *Journal of Petroleum Exploration and Production Technology*, 2017, vol. 7, no. 4, pp. 1023-1033. DOI: 10.1007/s13202-017-0360-0
40. Antariksa G., Muammar R., Lee J. Performance evaluation of machine learning-based classification with rock-physics analysis of geological lithofacies in Tarakan Basin, Indonesia. *Journal of Petroleum Science and Engineering*, 2022, vol. 208, 109250 p. DOI: 10.1016/j.petrol.2021.109250
41. Shakiba M. et al. Stochastic reconstruction of fracture network pattern using spatial point processes. *Geoenergy Science and Engineering*, 2024, vol. 236, 212741 p. DOI: 10.1016/j.geoen.2024.212741
42. Özbayrak F., Foster J.T., Pyrcz M.J. Spatial bagging to integrate spatial correlation into ensemble machine learning. *Computers & Geosciences*, 2024, vol. 186, 105558 p. DOI: 10.1016/j.cageo.2024.105558
43. Pyrcz M.J. Data analytics and geostatistical workflows for modeling uncertainty in unconventional reservoirs. *Bulletin of Canadian Petroleum Geology*, 2019, vol. 67, no. 4, pp. 273-282. DOI: 10.35767/gscpgbull.67.4.273
44. Pyrcz M.J., Deutsch C.V., Deutsch J.L. Transforming data to a gaussian distribution. *Geostatistics Lessons*, 2018, pp. 27-38.
45. Belozеров B. et al. Automatic well log analysis across priobskoe field using machine learning methods. *SPE Russian Petroleum Technology Conference*. SPE, 2018, D013S002R011 p. DOI: 10.2118/191604-18RPTC-MS
46. Budenny S. et al. Image processing and machine learning approaches for petrographic thin section analysis. *SPE Russian Petroleum Technology Conference*, SPE, 2017, D023S014R005 p. DOI: 10.2118/187885-MS

Финансирование. Исследование не имело спонсорской поддержки.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Вклад авторов равноценен.