



ФОРМАЛЬНЫЕ КРИТЕРИИ КАЧЕСТВА АВТОМАТИЧЕСКОЙ КОРРЕЛЯЦИИ РАЗРЕЗОВ СКВАЖИН

Владимир Валентинович Лапковский¹, Василиса Ивановна Шелудько^{2,✉}

¹Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН,
630090, Новосибирск, просп. Акад. Коптюга, 3, Россия,

^{1,2}Новосибирский государственный технический университет, 630073, Новосибирск, пр. К. Маркса, 20, Россия,

¹LapkovskiiVV@ipgg.sbras.ru, <https://orcid.org/0000-0002-6786-9101>

²vasilisasheludko@yandex.ru, <https://orcid.org/0009-0007-5385-6872>

Аннотация. Предлагаются и сравниваются формализованные критерии качества автоматической корреляции скважин. Рассмотрены три показателя: ошибка прогноза значений каротажных кривых на основе кросс-валидации; отношение средней внутригрупповой дисперсии к общей дисперсии данных; среднеквадратическое отклонение глубин набора стратиграфических границ от эталонной модели. Показана очень тесная статистическая связь для первых двух критериев, но в силу сравнительной простоты вычисления более предпочтительным оказывается второй из них. Критерий, связанный с оценкой отклонения от эталонной модели (созданной экспертом), может использоваться в машинном обучении для практических задач, но малопригоден, поскольку требует предварительного построения эталонной модели.

Ключевые слова: автоматическая корреляция разрезов скважин, ранжирование корреляционных моделей, стратиграфическая корреляция, критерии качества корреляции

Финансирование: исследование выполнено по плану базовых научно-исследовательских работ ИНГГ СО РАН (проект Минобрнауки РФ FWZZ-2022-0009).

Для цитирования: Лапковский В.В., Шелудько В.И. Формальные критерии качества автоматической корреляции разрезов скважин // Геофизические технологии. 2025. № 2. С. 51–59. doi:10.18303/2619-1563-2025-2-51.

FORMAL QUALITY CRITERIA FOR AUTOMATIC CORRELATION OF WELL LOGS

Vladimir V. Lapkovsky¹, Vasilisa I. Sheludko^{2,✉}

¹Trofimuk Institute of Petroleum Geology and Geophysics, SB RAS, Koptuyug Ave., 3, Novosibirsk, 630090, Russia,

^{1,2}Novosibirsk State Technical University, K. Marks Ave., 20, Novosibirsk, 630073, Russia,

¹LapkovskiiVV@ipgg.sbras.ru, <https://orcid.org/0000-0002-6786-9101>

²vasilisasheludko@yandex.ru, <https://orcid.org/0009-0007-5385-6872>

Abstract. This article proposes and compares formalized criteria for the quality of automated well correlation. Three indicators are considered: the error in predicting well log values based on cross-validation; the ratio of the average intra-group variance to the total data variance; and the standard deviation of the depths of a set of stratigraphic boundaries from a reference model. A very close statistical relationship is demonstrated for the first two criteria, but due to the comparative simplicity of calculation, the second is preferable. The criterion associated with assessing the deviation from the reference model (created by an expert) can be used in machine learning for practical tasks, but is of little use because it requires the preliminary construction of a reference model.

Keywords: automatic wellbore correlation, correlation model ranking, stratigraphic correlation, correlation quality criteria

Funding: The study was carried out as part of government assignment to the Russian Academy of Sciences in basic research, Project FWZZ-2022-0009.

For citation: Lapkovsky V.V., Sheludko V.I. Formal quality criteria for automatic correlation of well logs // Russian Journal of Geophysical Technologies. 2025. No. 2. P. 51–59. (In Russ.). doi:10.18303/2619-1563-2025-2-51.

ВВЕДЕНИЕ

Стратиграфическая корреляция является ключевым звеном между первичными данными бурения и объемной моделью месторождения, позволяя геологам строить структурные карты продуктивных отложений и модели распределения петрофизических свойств. Процесс корреляции, в большинстве случаев, включает попарное визуальное сравнение скважин, что делает его субъективным и зависимым от опыта интерпретатора, его искусства чтения каротажных кривых. Это приводит к неопределенности в оценках залежей. Проблему не устраняет наличие компьютерных технологий для сопоставления скважин. При этом выбор того или иного варианта сопоставления может существенно повлиять на результаты дальнейшего моделирования, оценки запасов, представление об их локализации и пространственной изменчивости петрофизических свойств. И если традиционно геолог мог рассмотреть малое число альтернативных вариантов корреляции, то на основе компьютерных технологий возможна генерация весьма большого числа корреляционных моделей, которые необходимо оценивать и выбирать наиболее обоснованные. Здесь весьма полезным было бы наличие сформулированных вычисляемых формальных критериев для такой оценки. Пока данный вопрос проработан слабо, и соответствующий инструментарий не реализован в индустриальных программных продуктах.

В настоящее время заметный рост наблюдается в использовании искусственного интеллекта для решения задач идентификации геологических границ и межскважинной корреляции слоев [Шайбаков, 2012; Bakdi et al., 2022; Romanenkova et al., 2022; Латыпов и др., 2024]. Основная проблема в этой области – обучение нейронных сетей и других моделей так, чтобы они могли по набору исходных геофизических данных генерировать разумные корреляционные решения. Как показывает анализ литературы, обучение основывается на настройке параметров в процессе подачи совместно с данными каротажа правильных вариантов корреляции. Модели правильной корреляции должны быть подготовлены заранее до обучения сети. Это делает задачу обучения довольно трудозатратной. И именно здесь весьма благоприятно было бы наличие формального критерия оценки качества корреляции, что позволило бы генерировать множество схем корреляции и подавать их для обучения сети, ранжировав по качеству. Сеть могла бы обучаться не только на хороших примерах работы, но и на примерах некорректной корреляции.

МАТЕРИАЛЫ И МЕТОДЫ

Результаты, представленные в статье, получены на данных геофизических исследований скважин одного из кустов Казанского нефтегазоконденсатного месторождения Томской области. Корреляция разрезов скважин и оценка качества полученных моделей выполнены по данным гамма-гамма плотностного каротажа (ГГКП).

Метод корреляции был ранее описан в статье [Лапковский и др., 2015], он заключается в решении оптимизационной задачи сопоставления двух рядов данных на основе DTW (Dynamic Time Warping)

алгоритма. Один из используемых критериев оценки качества сформулирован ранее в работе [Лапковский и др., 2019]. Его идея состоит в том, что более качественная корреляция способствует более точному прогнозу свойств в скважинах. На основе конкретной корреляционной модели методом кросс-валидации вычисляется погрешность прогноза для одной или нескольких каротажных кривых. Лучшему варианту корреляции соответствует меньшая погрешность прогноза.

В этой статье предлагается еще два критерия оценки корреляционного решения:

1. Один из них использует более простые вычисления, не связанные с реализацией алгоритма кросс-валидации по схеме Leave-one-out. Этот критерий основан на сопоставлении дисперсий. То есть задача корреляции рассматривается как своего рода кластеризация (стратиграфически эквивалентные точки принадлежат одному классу). Далее для одной или нескольких каротажных кривых вычисляются средняя внутриклассовая (внутригрупповая) дисперсия и ее доля от общей дисперсии. Дадим несколько пояснений.

У нас имеется N скважин, вскрывающих разрез, стратиграфический диапазон которого параметризован значениями от $stratoMin$ до $stratoMax$. В этом диапазоне мы выделим M реперов. Проще всего определить стратиграфическое значение k -того репера (k от 0 до $M - 1$) как

$$S_k = stratoMin + (stratoMax - stratoMin)/(M - 1).$$

Берем все измерения некоторого каротажа во всех скважинах на каждом выделенном реперном уровне. Таким образом, имеем $N \cdot M$ значений, для которых вычисляется общая дисперсия. Также для каждого из M реперных уровней вычисляем внутригрупповую дисперсию, что позволяет оценить среднюю внутригрупповую дисперсию. Далее вычисляем отношение средней внутригрупповой дисперсии к общей. В качестве критерия мы, по существу, вычисляем величину обратную индексу Калински–Харабаса [Caliński, Harabasz, 1974], который успешно используется для оценки качества кластеризации данных (обратная величина берется нами, чтобы данный критерий имел то же направление, что и основанные на погрешности прогноза: меньшее значение – лучший вариант). Вычисление немного усложняется, если имеются короткие скважины, не вскрывающие весь стратиграфический диапазон.

2. Другой критерий измеряет различие между текущим вариантом корреляции и эталонным (правильным) по заданному набору границ слоев. Этот критерий предполагает наличие правильного варианта корреляции. Эталонный вариант корреляции соответствует некоторой таблице (табл. 1). Делая очередной вариант корреляции, мы получаем таблицу того же размера, но с другими значениями. Используемый критерий – среднеквадратическое отклонение значений этих таблиц. По сути, это среднеквадратическая ошибка корреляции, в нашем случае – в метрах.

Результаты, представленные ниже, получены в ходе корреляции отложений верхней части васюганской свиты.

СРАВНЕНИЕ КРИТЕРИЕВ КАЧЕСТВА КОРРЕЛЯЦИИ

Корреляционную модель можно представить в виде таблицы, строки которой – скважины, а столбцы – коррелируемые стратиграфические уровни, значения в таблице – измеренная глубина в скважине различных стратиграфических границ.

Корреляционная модель

	Bg1	Bg	Gr	Vs	Y_1_0_K_mt	Y_1_0_K_mb	Y_1_1_A_t	Y_1_1_A_b	Y_1_1_B_t	Y_1_1_B_b	Y_1_2t	Y_1_2b	Y_2_0t
1	2901.86	2917.06	2924.39	2930.34	2938.51	2939.03	2954.36	2956.65	2958.12	2959.61	2971.47	2979.54	2996.8
2	2857.22	2874.17	2881.53	2887.82	2897.06	2897.5	2911.16	2913.26	2921.13	2922.53	2926.57	2935.13	2957.41
3	2932.8	2949.65	2957.05	2963.94	2973.42	2973.87	2988.49	2990.86	2991.7	2993.24	3005.2	3012.02	3031.38
4	2876.22	2893.49	2900.79	2907.84	2916.04	2916.49	2929.08	2930.97	2934.17	2935.72	2947.8	2953.73	2976.06
5	2597.51	2613.95	2621.62	2628.5	2638.11	2638.93	2653.7	2656.28	2657.54	2658.93	2671.47	2679.84	2697.77
6	2550.37	2567.62	2575.13	2582.23	2591.35	2591.73	2606.97	2609.23	2610.75	2611.96	2623.34	2630.48	2648.25
7	2439.61	2456.55	2463.92	2470.67	2479.52	2480.07	2496.6	2498.68	2499.95	2501.47	2514.19	2521.35	2542.45
8	2605.86	2621.87	2629.55	2636.51	2646.1	2646.76	2660.59	2662.87	2667.51	2669.01	2680.35	2688	2705.94
9	2595.11	2611.79	2619.25	2625.68	2633.85	2634.34	2647.24	2649.02	2653.96	2655.33	2667.14	2675.28	2695.51
10	2792.33	2808.85	2816.54	2822.82	2831.87	2832.34	2848.36	2850.83	2852.04	2853.66	2864.45	2872.9	2887.33
11	2947.07	2963.61	2971.27	2977.94	2986.83	2987.28	3002.48	3005.12	3006	3007.8	3019.14	3026.09	3041.99

Вместе с данными ГГКП по скважинам и литологическими колонками эта модель представляется разрезом (рис. 1). Показанный разрез является эталонным (правильно прокоррелированным с точки зрения интерпретатора).

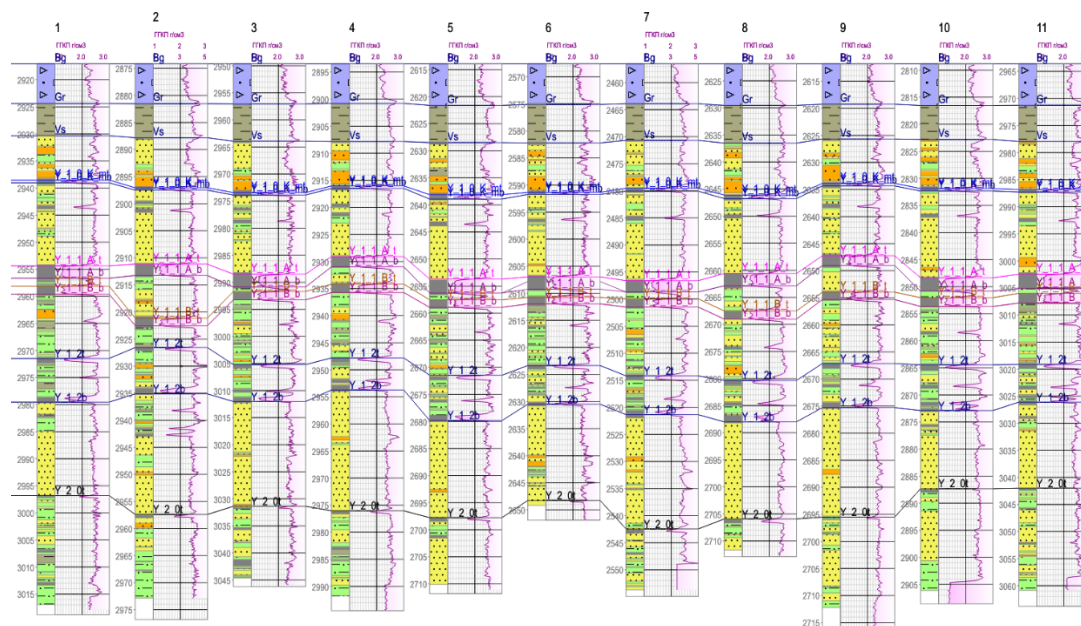


Рис. 1. Разрез по 11 скважинам баженовской, георгиевской и верхней части васюганской свит.

Для оценки критериев качества корреляции из модели была удалена большая часть границ пластов в пределах васюганской свиты (ниже границы Vs). Полученный разрез (рис. 2) проходил процедуру автоматической корреляции в разных режимах, и для каждого варианта вычислялись значения критериев качества. Как видно из рисунка, интервал, в котором реально выполнялось построение модели, ограничен двумя уровнями – кровлей васюганской свиты и кровлей одного из угольных пластов (Y_2_0t). Эти два уровня были заданы во всех скважинах. Остальные стратиграфические границы внутри васюганской свиты представлены в четвертой скважине и очень редко в других скважинах.

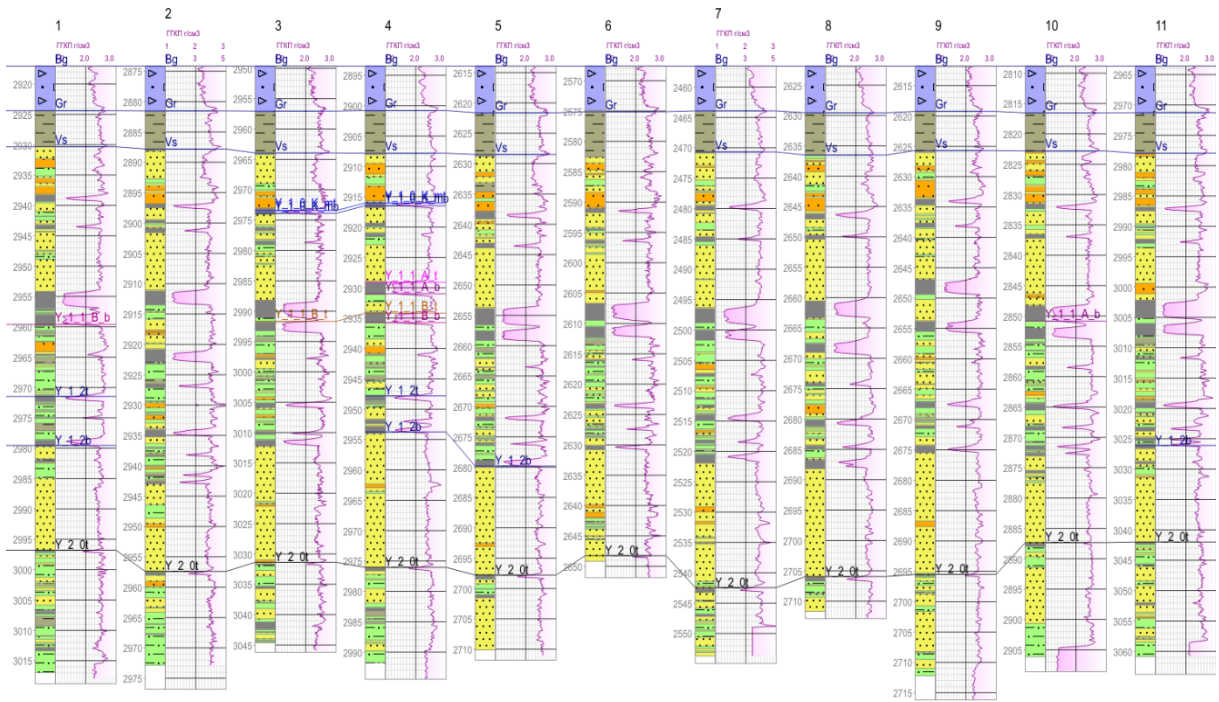


Рис. 2. Исходная модель для корреляции разрезов скважин.

Таблица стратиграфических разбивок исходной модели имеет многочисленные пробелы. Задача корреляции – заполнить эти пробелы, после чего могут быть вычислены критерии качества. Всего было построено 10 различных вариантов корреляции скважин, здесь мы показываем только один из них и совсем не лучший (рис. 3).

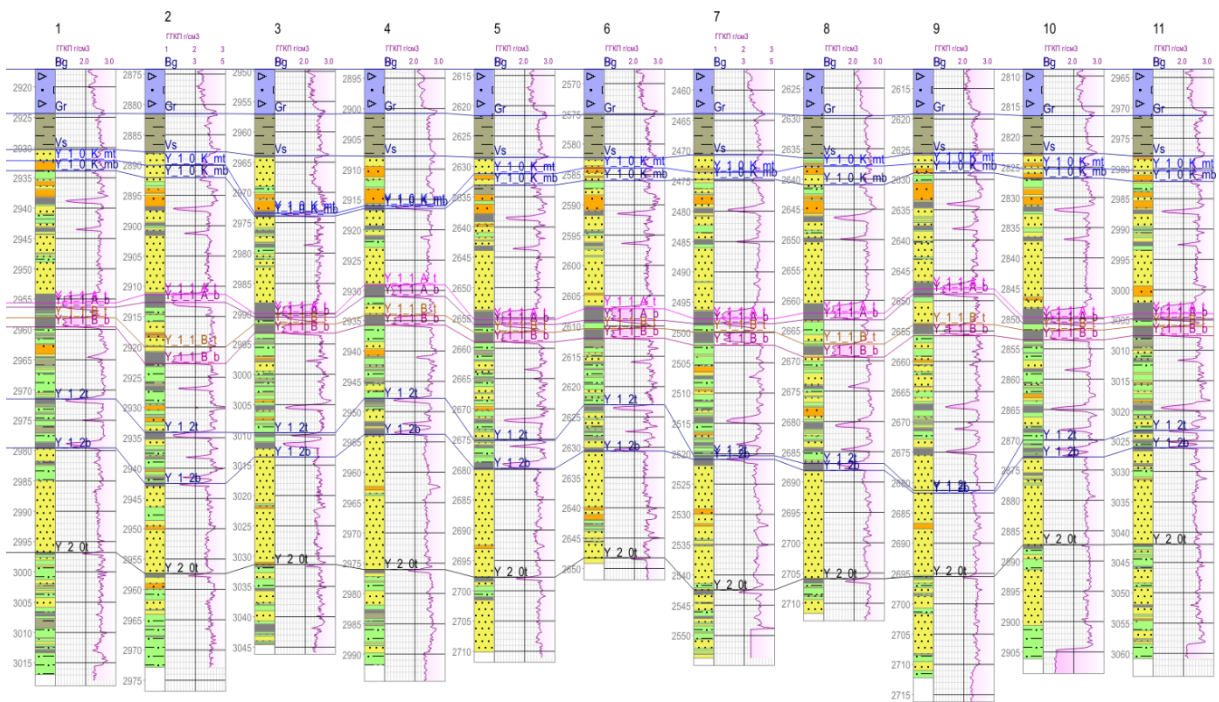


Рис. 3. Один из вариантов корреляции разрезов скважин.

Предложенный ранее критерий, основанный на вычислении погрешности корреляции, и отношение дисперсий (критерий, предлагаемый в данной статье) оказались достаточно тесно связаны

линейной зависимостью (рис. 4). Коэффициент корреляции для них составил +0.97. Это вполне естественно: чем меньше внутригрупповая дисперсия, тем меньше и погрешность прогноза значений для данной группы. То есть вместо индикатора, вычисление которого требует многочисленных экспериментов с пространственной интерполяцией данных (что необходимо при реализации методов кросс-валидации), можно использовать вычисление внутригрупповых дисперсий для каждой стратиграфически эквивалентной группы точек в стволах разных скважин. Это намного проще, а результат почти неотличим.




Рис. 4. Линейная зависимость между двумя критериями качества корреляционной модели.




Рис. 5. Соотношение среднеквадратической ошибки корреляционной модели и двух критериев качества. Ряд 1 – отношение дисперсий, Ряд 2 – погрешность прогноза ГКП.

Рисунок 5 показывает довольно сильную зависимость используемых критериев качества корреляции от среднеквадратического отклонения от эталонной корреляции. Для каждого из критериев коэффициент корреляции с погрешностью модели (отклонение в метрах) составил около +0.85. Чуть больше он оказался для отношения дисперсий. По-видимому, геолог, сравнивая варианты корреляции,

оценивает их по величине отклонения от некоторой идеальной модели, которую он представляет. В этом отношении надежным критерием качества могла бы быть среднеквадратическая погрешность корреляционной модели (ось X на рис. 5). Но это очень неудобный параметр: чтобы его вычислить, надо предварительно создать эталонную корреляционную модель. Возможно, для обучения нейронных сетей искусству корреляции такой подход приемлем, но для работы с реальными данными он мало пригоден. Хорошим обстоятельством здесь является то, что критерии, вычисляемые по самой модели в отсутствие эталона (отношение дисперсий и погрешность прогноза свойств), имеют весьма тесную линейную связь с критерием, который вычисляется в сравнении с эталоном.

ЗАКЛЮЧЕНИЕ

Полученные результаты являются новыми и важными для задачи стратиграфической корреляции. Корреляционные модели традиционно оценивались путем неформальной экспертизы. На основании предложенных в статье критериев возможно эффективно ранжировать модели сопоставления разрезов скважин в числовых метриках. Это позволяет подбирать оптимальные параметры для вычислительных процедур, а также имеет хорошие перспективы для создания эффективных технологий обучения нейронных сетей и других методов, связанных с использованием искусственного интеллекта и машинного обучения. Числовое выражение качества корреляции позволяет реализовывать процедуры оптимизации весовых коэффициентов нейронных сетей и градиентного спуска при многомерной оптимизации.

В дальнейшем планируется провести сравнение и анализ формальных критериев качества корреляции с оценками и ранжированием моделей, которые выполняются несколькими квалифицированными специалистами. Вычисление критериев качества будет включено в плагины стратиграфических корреляций для среды W-Seis интерпретации геолого-геофизических данных.

Мы думаем об исследованиях в области создания корреляционных решений на основе ИИ, при этом для обучения сетей предполагаем использовать разработанные критерии качества.

СПИСОК ИСТОЧНИКОВ

Лапковский В.В., Истомин А.В., Конторович В.А., Бердов В.А. Корреляция разрезов скважин как многомерная оптимизационная задача // Геология и геофизика. 2015. Т. 56, № 3. С. 624–630. doi:10.15372/GiG20150309. EDN:TNUWLJ.

Лапковский В.В., Моисеев С.А., Лунев Б.В. Критерий качества автоматической корреляции разрезов скважин по каротажным данным // Геофизические технологии. 2019. № 2. С. 12–22. doi: 10.18303/2619-1563-2019-2-12. EDN:VTZOZN.

Латыпов И.Д., Марков А.В., Евграфов Н.А., Шагмарданова Л.Р. Разработка подходов к автоматизированной внутрипластовой корреляции по данным геофизических исследований скважин с применением машинного обучения // Экспозиция Нефть Газ. 2024. № 4. С. 47–51. doi: 10.24412/2076-6785-2024-4-47-51. EDN:GVMMOB.

Шайбаков Р.А. Использование нейросетевого аппарата для идентификации границ геологических объектов // Технические науки: традиции и инновации: Материалы I Международной научной конференции. Челябинск: Два комсомольца, 2012. С. 8–11. <https://moluch.ru/conf/tech/archive/6/1491>.

Bakdi S., Kannan N., Masini S., Chennakrishnan B. Automated well correlation using machine learning and facial recognition techniques // Abu Dhabi International Petroleum Exhibition & Conference. 2020. doi:10.2118/203301-MS.

Caliński T., Harabasz J. A dendrite method for cluster analysis // Communications in Statistics. 1974. Vol. 3 (1). P. 1–27. doi:10.1080/03610927408827101.

Romanenkova E., Rogulina A., Shakirov A., Stulov N., Zaytsev A., Ismailova L., Kovalev D., Katterbauer K., AlShehri A. Similarity learning for wells based on logging data // Journal of Petroleum Science and Engineering. 2022. Vol. 215 (Part B). 110690. doi:10.1016/j.petrol.2022.110690.

REFERENCES

Bakdi S., Kannan N., Masini S., Chennakrishnan B. Automated well correlation using machine learning and facial recognition techniques // Abu Dhabi International Petroleum Exhibition & Conference. 2020. doi:10.2118/203301-MS.

Caliński T., Harabasz J. A dendrite method for cluster analysis // Communications in Statistics. 1974. Vol. 3 (1). P. 1–27. doi:10.1080/03610927408827101.

Lapkovsky V.V., Istomin A.V., Kontorovich V.A., Berdov V.A. Correlation of well logs as a multidimensional optimization problem // Russian Geology and Geophysics. 2015. Vol. 56 (3). P. 487–492. doi:10.1016/j.rgg.2015.02.009.

Lapkovsky V.V., Moiseev S.A., Lunev B.V. Quality criteria for automatic correlation of well sections based on logging data // Russian Journal of Geophysical Technologies. 2019. No. 2. P. 12–22. (In Russ.). doi:10.18303/2619-1563-2019-2-12.

Latypov I.D., Markov A.V., Evgrafov N.A., Shagimardanova L.R. Development of approaches to automated correlation from well log data using machine learning // Exposition Oil Gas. 2024. No. 4. P. 47–51. (In Russ.). doi:10.24412/2076-6785-2024-4-47-51.

Romanenkova E., Rogulina A., Shakirov A., Stulov N., Zaytsev A., Ismailova L., Kovalev D., Katterbauer K., AlShehri A. Similarity learning for wells based on logging data // Journal of Petroleum Science and Engineering. 2022. Vol. 215 (Part B). 110690. doi:10.1016/j.petrol.2022.110690.

Shaibakov R.A. Using a neural network device for identifying the boundaries of geological objects (In Russ.) // Engineering Sciences: Traditions and Innovations: Proceedings of the First International Scientific Conference. Chelyabinsk, 2012. P. 8–11. <https://moluch.ru/conf/tech/archive/6/1491>.

ИНФОРМАЦИЯ ОБ АВТОРАХ

ЛАПКОВСКИЙ Владимир Валентинович – доктор геолого-минералогических наук, ведущий научный сотрудник лаборатории сейсмогеологического моделирования природных нефтегазовых систем Института нефтегазовой геологии и геофизики СО РАН. Профессор кафедры Вычислительной техники Новосибирского государственного технического университета. Основные научные интересы: математические методы изучения строения осадочных бассейнов, создание стратиграфических моделей, использование геостатистики и многомерных сплайнов для прогнозирования петрофизических свойств, разработка профессионального программного обеспечения.

ШЕЛУДЬКО Василиса Ивановна – аспирант Новосибирского государственного технического университета, ассистент кафедры вычислительной техники Новосибирского государственного технического университета. Основные научные интересы связаны с задачами многомерной оптимизации, анализа временных рядов и искусственного интеллекта.

*Статья поступила в редакцию 25 ноября 2025 г.,
одобрена после рецензирования 28 ноября 2025 г.,
принята к публикации 28 ноября 2025 г.*