



Научная статья

УДК 552.578.2+519.677+004.032.26

<https://doi.org/10.21285/2686-9993-2021-44-4-408-416>

Разработка новой эмпирической корреляции для прогнозирования объемного коэффициента пластовой нефти с использованием методов искусственного интеллекта

Эльвира Венеровна Шакирова^а, Александр Андреевич Александров^б,
Михаил Вячеславович Семькин^с

^{а,с}Иркутский национальный исследовательский технический университет, г. Иркутск, Россия

^бТюменский государственный университет, г. Тюмень, Россия

Автор, ответственный за переписку: Шакирова Эльвира Венеровна, viva160@mail.ru

Резюме. Известно, что для нефти, находящейся в пластовых условиях, характерно содержание определенного количества растворенного газа. В процессе снижения пластового давления этот газ выделяется из нефти, существенно изменяя ее физические свойства, в первую очередь плотность и вязкость. Кроме того, происходит уменьшение объема нефти, иногда на 50–60 %. В связи с этим при подсчете запасов необходимо обосновать величину, на которую уменьшится объем пластовой нефти после извлечения ее на поверхность. Для этого введено понятие объемного коэффициента пластовой нефти. Объемный коэффициент нефти считается одним из основных параметров, необходимых для определения характеристик сырой нефти, а также для моделирования и прогнозирования характеристик нефтяного коллектора. Целью данного исследования являлась разработка новой эмпирической корреляции для прогнозирования объемного коэффициента пластовой нефти с использованием методов искусственного интеллекта на базе программного обеспечения MATLAB, таких как искусственная нейронная сеть, адаптивная нейро-нечеткая система вывода и метод опорных векторов. В работе представлена новая эмпирическая корреляция, извлеченная из искусственной нейронной сети на основе 503 экспериментальных точек данных для нефтей с месторождения Восточной Сибири, которая помогла спрогнозировать объемный коэффициент нефти с коэффициентом корреляции 0,969 и средней абсолютной ошибкой меньше 1 %. Проведенное исследование показывает, что точность прогнозирования искомого параметра в разработанной модели искусственного интеллекта превосходит точность результатов исследований с применением обычных статистических методов. Также данная модель может быть полезна в перспективе оптимизации процессов при планировании и разработке месторождений.

Ключевые слова: объемный коэффициент нефти, искусственный интеллект, нейронные сети, коэффициент корреляции

Для цитирования: Шакирова Э. В., Александров А. А., Семькин М. В. Разработка новой эмпирической корреляции для прогнозирования объемного коэффициента пластовой нефти с использованием методов искусственного интеллекта // Науки о Земле и недропользование. 2021. Т. 44. № 4. С. 408–416. <https://doi.org/10.21285/2686-9993-2021-44-4-408-416>.

Original article

Development of a new empirical correlation for predicting formation volume factor of reservoir oil using artificial intelligence

Elvira V. Shakirova^а, Aleksandr A. Aleksandrov^б, Mikhail V. Semykin^с

^{а,с}Irkutsk National Research Technical University, Irkutsk, Russia

^бUniversity of Tyumen, Tyumen, Russia

Corresponding author: Elvira V. Shakirova, viva160@mail.ru

Abstract. It is known that oil in reservoir conditions is characterized by the content of a certain amount of dissolved gas. As reservoir pressure decreases this gas is released from oil significantly changing its physical properties, primarily its density and viscosity. In addition, the oil volume also reduces, sometimes by 50–60 %. In this regard, when calculating reserves, it is necessary to justify the reduction amount of the reservoir oil volume when oil is extracted to the surface. For this purpose, the concept of formation volume factor of reservoir oil has been introduced. The formation volume factor



of oil is considered one of the main characterizing parameters of crude oil. It is also required for modeling and predicting the characteristics of an oil reservoir. The purpose of the present work is to develop a new empirical correlation for predicting the formation volume factor of reservoir oil using artificial intelligence methods based on MATLAB software, such as: an artificial neural network, an adaptive neuro-fuzzy inference system, and a support vector machine. The article presents a new empirical correlation extracted from the artificial neural network based on 503 experimental data points for oils from the Eastern Siberia field, which was able to predict the formation volume factor of oil with the correlation coefficient of 0.969 and average absolute error of less than 1 %. The conducted study shows that the prediction accuracy of the desired parameter in the developed artificial intelligence model exceeds the accuracy of study results obtained by conventional statistical methods. Moreover, the model can be useful in the prospect of process optimization in field planning and development.

Keywords: oil formation factor, artificial intelligence, neural networks, correlation coefficient

For citation: Shakirova E. V., Aleksandrov A. A., Semykin M. V. Development of a new empirical correlation for predicting formation volume factor of reservoir oil using artificial intelligence. *Nauki o Zemle i nedropol'zovanie = Earth sciences and subsoil use*. 2021;44(4):408-416. (In Russ.). <https://doi.org/10.21285/2686-9993-2021-44-4-408-416>.

Введение

Свойства пластовой нефти имеют решающее значение для вычислительных технологий в области разработки месторождений. Эти свойства включают коэффициент объема нефтяного пласта, давление насыщения, газорастворимость в нефти и т. д. Коэффициент объема нефтяного пласта определяет соотношение между объемом нефти в пласте с растворенным газом и объемом нефти на поверхности. Для всех расчетов материального баланса требуется объемный коэффициент пластовой нефти для определения объема коллектора после процесса истощения. Объемный коэффициент нефти сильно зависит от пластового давления, и в некоторых случаях данные по коэффициенту объема нефтеносного пласта недоступны. Поэтому следует разработать корреляции и модели для прогнозирования, которые могут быть использованы в расчетных моделях коллектора.

Приложения для разработки месторождений, такие как уравнение материального баланса, моделирование коллектора и испытания скважин, нуждаются в свойствах давления, объема и температуры нефтяных пластовых флюидов, и одним из этих свойств является объемный коэффициент пластовой нефти. Объемным коэффициентом нефти называют отношение объема нефти, который она занимает в пластовых условиях, к объему получаемой из нее дегазированной нефти в стандартных условиях.

Целью данной работы являлась разработка новой эмпирической корреляции для прогнозирования объемного коэффициента пластовой нефти с использованием методов

искусственного интеллекта, таких как искусственная нейронная сеть (*англ.*: Artificial neural networks, ANN), адаптивная нейро-нечеткая система вывода (*англ.*: Adaptive neuro-fuzzy inference system, ANFIS) и метод опорных векторов (*англ.*: Support vector machine, SVM).

Материалы и методы исследования

Первым шагом проведенного исследования стал сбор данных с нефтегазоконденсатного месторождения Восточной Сибири. Этап обработки этой информации включал в себя проверку качества доступных данных, удаление выбросов и при необходимости применение техники нормализации [1]. Искомыми параметрами были объемный коэффициент нефти b , газонасыщенность G , плотность газа ρ_g , плотность нефти ρ_n и температура коллектора T . Данные образцов нефтей, собранных с исследуемого месторождения (503 точки), приведены в таблице.

Газонасыщенность находилась в диапазоне $311 \text{ м}^3/\text{т}$ с минимальным значением $9 \text{ м}^3/\text{т}$ и максимальным значением $7283 \text{ м}^3/\text{т}$. Плотность газа имела диапазон $0,8 \text{ кг}/\text{м}^3$ с минимальным значением $0,713 \text{ кг}/\text{м}^3$ и максимальным значением $0,856 \text{ кг}/\text{м}^3$. Плотность нефти находилась в диапазоне $0,848 \text{ т}/\text{м}^3$ с минимальным значением $0,81 \text{ т}/\text{м}^3$ и максимальным значением $0,884 \text{ т}/\text{м}^3$. Температура коллектора имела диапазон $16 \text{ }^\circ\text{C}$ с минимальным значением $14 \text{ }^\circ\text{C}$ и максимальным значением $24 \text{ }^\circ\text{C}$. Объемный коэффициент нефти имел диапазон $1,184 \text{ м}^3/\text{м}^3$ с минимальным значением $1,138 \text{ м}^3/\text{м}^3$ и максимальным значением $1,29 \text{ м}^3/\text{м}^3$.



Полученные данные с месторождения Восточной Сибири Data obtained on the field in Eastern Siberia

Номер образца	Входные параметры				Выходной параметр
	Газонасыщенность, м ³ /т	Плотность газа, кг/м ³	Плотность нефти, т/м ³	Температура коллектора, °С	Объемный коэффициент нефти, м ³ /м ³
1	1390	0,81	0,81	24	1,29
2	4476	0,803	0,85	14	1,14
3	5377	0,786	0,85	14	1,14
4	54	0,856	0,849	16	1,18
5	45	0,791	0,849	16	1,18
6	742	0,713	0,849	16	1,18
7	31	0,82	0,849	16	1,18
...
501	149	0,8	0,884	20,8	1,19
502	217	0,8	0,832	20	1,23
503	131	0,8	0,832	20	1,23

Вторым шагом в исследовании стала разработка и обучение трех моделей искусственного интеллекта для прогнозирования искомого параметра [1].

Для первой модели был реализован алгоритм нейронной сети обратного распространения. Предлагаемая модель искусственной нейронной сети была основана на газонасыщенности, плотности газа, плотности нефти и температуре коллектора с одним скрытым слоем и одним выходным параметром. Количество нейронов в скрытом слое оказалось равным 20. В качестве передаточной функции между входным и скрытым слоями использовалась функция активации сигмоидального типа, а также функция активации линейного типа между скрытым и выходным слоями. Алгоритм обратного распространения Левенберга – Марквардта был выбран в качестве алгоритма обучения для получения весов и смещений [2]. Во избежание застревания модели на локальных минимумах было выполнено 10000 реализаций с инициализацией различных весов и смещений на этапах обучения и перекрестной проверки моделирования. После обучения были извлечены веса и смещения из оптимальной модели [3, 4].

Вторая модель была основана на типе Genfis2 [5, 6] (субтрактивная кластеризация) с радиусом кластера 0,5. Оптимальный размер радиуса кластера был найден путем анализа чувствительности радиусов кластера от 0,1 до 1. Оптимальный размер эпохи был найден равным 500. Чтобы избежать застревания

модели на локальных минимумах, было выполнено 10000 реализаций.

Третья модель была основана на функции ядра гауссовского типа с параметром регуляризации C , равным 5000. Функция ядра гауссовского типа была выбрана путем сравнения производительности прогнозирования с функцией ядра полиномиального типа [7, 8], поскольку функция ядра гауссовского типа предсказывала лучшие результаты, чем функция ядра полиномиального типа. Оптимальное значение параметра регуляризации было найдено равным 5000 путем определения параметров чувствительности значений от 250 до 5000.

Результаты исследования

Искусственная нейронная сеть – это самый мощный статистический инструмент для распознавания и классификации сложных паттернов и систем, которые не может сделать человеческий мозг. Метод искусственной нейронной сети основан на биологических нейронах, обнаруженных в человеческом мозге. Данная модель содержит основной блок обработки, называемый нейронами. Модели нейронных сетей состоят из трех компонентов: алгоритма обучения, передаточной функции и сетевой архитектуры [2]. Сетевая модель состоит как минимум из трех слоев: входного, скрытого и выходного. Каждый слой соединяется с другими слоями с помощью утяжелителей. Производительность сети основана исключительно на регулировке весов



между этими уровнями [3, 4]. Результат обучения первой модели искусственного интеллекта приведен на рис. 1.

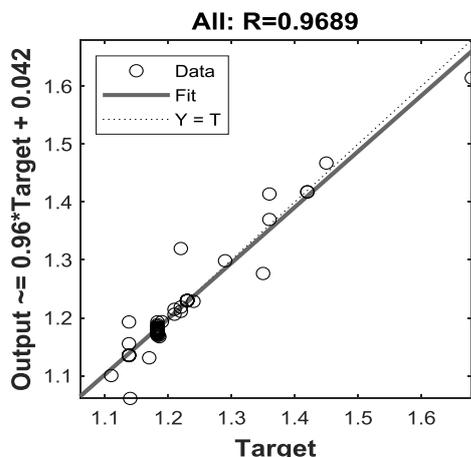


Рис. 1. Результаты обучения первой модели искусственного интеллекта
Fig. 1. Training results of the first model of artificial intelligence

Адаптивная нейро-нечеткая система вывода также приобретает доминирующее значение в нефтяной промышленности. Многие исследователи использовали в рассматриваемой отрасли данную систему для определения сложных концепций [6, 7]. Адаптивная нейро-нечеткая система вывода – это сочетание нейронной сети и нечеткой логики, а также

очень надежной техники контролируемого обучения. Это разновидность нейронной сети, в которой используется система нечеткого вывода Сугено [8]. Данный метод позволяет извлекать преимущества обоих упомянутых методов искусственного интеллекта на единой платформе. Чтобы получить от адаптивной нейро-нечеткой системы вывода максимальную отдачу, следует использовать любой эволюционный алгоритм для оптимизации параметров этого метода [4].

Нечеткая логика сопоставляет входные параметры с входными функциями принадлежности, преобразовывая входные функции принадлежности в набор нечетких правил, а набор нечетких правил – в выходные характеристики, затем – выходные характеристики в выходные функции принадлежности и, наконец, эту функцию принадлежности в однозначные выходные данные или любую классификацию на основе на выходе [5]. Вместо того, чтобы просто фиксировать форму функции принадлежности, метод адаптивной нейро-нечеткой системы вывода автоматически присваивает тип и форму функции принадлежности путем анализа данных [9]. Результаты обучения второй модели искусственного интеллекта приведены на рис. 2.

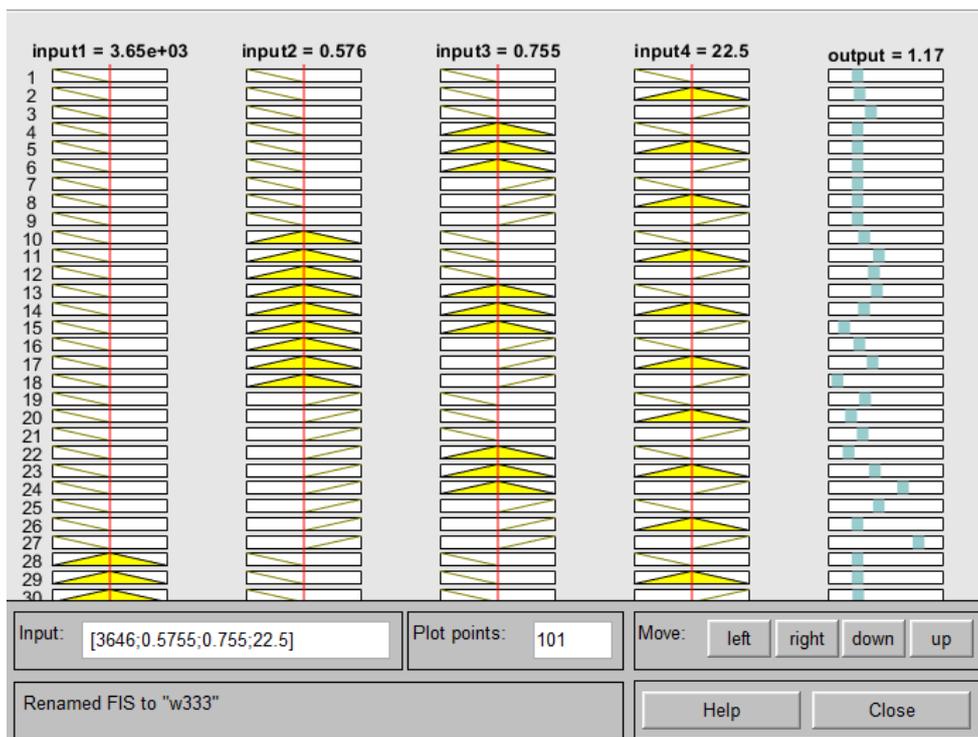


Рис. 2. Результаты обучения второй модели искусственного интеллекта
Fig. 2. Training results of the second model of artificial intelligence



Метод опорных векторов – это тип обучения, который используется в основном для целей регрессии и распознавания образов [10, 11]. Метод опорных векторов гиперплоскости был представлен в качестве новой инструментальной среды искусственного интеллекта как для классификации, так и для аппроксимации функций [12, 13]. Вместо передаточной функции сигмоидального типа, как в первой модели, данный метод опирается на функцию ядра нейрона, которая позволяет проецировать объект исследования на более сложные плоскости и может решать более сложные высоконелинейные задачи [14–16]. Результаты обучения третьей модели искусственного интеллекта приведены на рис. 3.

В ходе исследования выяснилось, что первая модель смогла предсказать объемный коэффициент с коэффициентом корреляции 0,969 и средней абсолютной ошибкой 0,11 %. Вторая модель смогла предсказать объемный коэффициент с коэффициентом корреляции 0,84 и средней абсолютной ошибкой 1,5 %. Третья модель смогла предсказать объемный коэффициент с коэффициентом корреляции 0,946 и средней абсолютной ошибкой 3,5 % при сравнении фактических и прогнозируемых значений объемного коэффициента.

Обсуждение полученных результатов

Объемный коэффициент нефти является важным параметром для дальнейшего определения запасов нефти и подсчета материального баланса месторождения [17–20]. Разработанные модели искусственного интеллекта показали большой коэффициент корреляции для определения объемного коэффициента нефти: 0,969, 0,84 и 0,946 соответственно. Методы машинного обучения свидетельствуют о хорошем прогнозе данных тестов и их способности выполнять расчеты, для которых ранее использовались традиционные статистические методы. На каждом этапе цепочки разработки нефтегазовых запасов возможно существенное ускорение и удешевление процессов, повышение эффективности при помощи использования массива данных, который накапливается во время работы, для дальнейшего обучения нейронных сетей. Внедрение сквозных цифровых технологий в нефтегазовой отрасли понятно в плане применения и экономически обосновано. Искусственный интеллект является наилучшим методом определения объемного коэффициента пластовой нефти благодаря высокой скорости и точности, когнитивные технологии широко применяются в обработке больших данных.

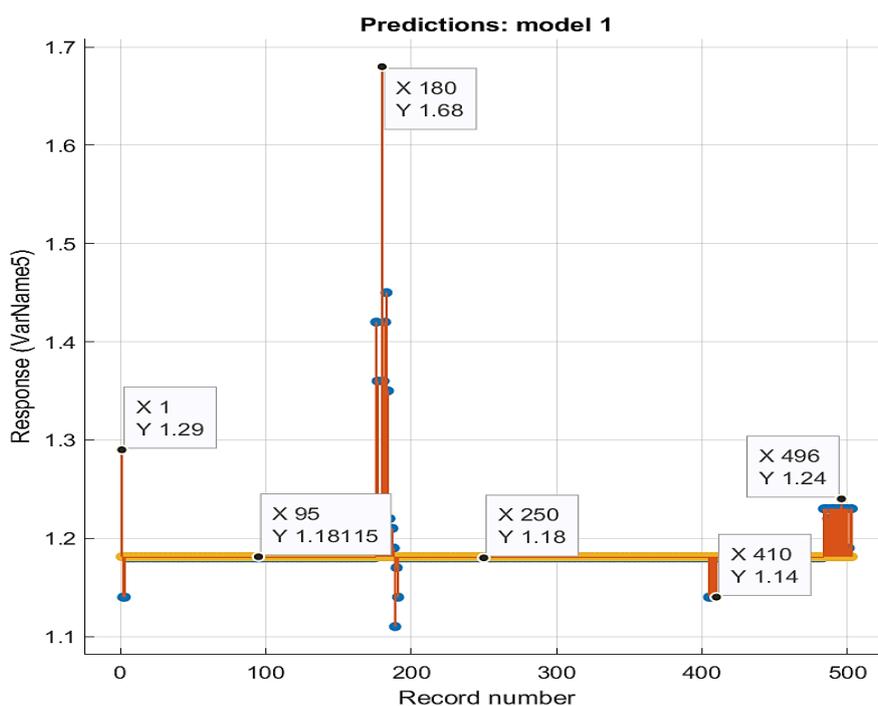


Рис. 3. Результаты обучения третьей модели искусственного интеллекта
Fig. 3. Training results of the third model of artificial intelligence



Заключение

Таким образом, в ходе проведенного исследования были разработаны три модели искусственного интеллекта для прогнозирования объемного коэффициента как функции газосодержания, плотности газа, плотности нефти и температуры коллектора. На основании полученных результатов можно сделать следующие выводы:

– первая разработанная модель является лучшим методом искусственного интеллекта,

который может предсказать объемный коэффициент нефти по таким параметрам, как газосодержание, плотность газа, плотность нефти и температура коллектора;

– модель искусственной нейронной сети имеет коэффициент корреляции 0,97 и среднюю абсолютную ошибку менее 1 %;

– модель искусственной нейронной сети может использоваться на производстве для прогнозирования объемного коэффициента с высокой точностью.

Список источников

1. Lippmann R. P. An introduction to computing with neural nets // IEEE ASSP Magazine. 1987. Vol. 4. Iss. 2. P. 4–22.
2. Hinton G. E., Osindero S., Teh Y.-W. A fast learning algorithm for deep belief nets // Neural Computation. 2006. Vol. 18. Iss. 7. P. 1527–1554. <https://doi.org/10.1162/neco.2006.18.7.1527>.
3. Rammay M. H., Abdurhaheem A. Automated history matching using combination of adaptive neuro fuzzy system (ANFIS) and differential evolution algorithm // SPE Large Scale Computing and Big Data Challenges in Reservoir Simulation Conference and Exhibition. Istanbul, 2014. SPE-172992-MS.
4. Ben-Hur A., Horn D., Siegelmann H. T., Vapnik V. Support vector clustering // Journal of Machine Learning Research. 2001. Vol. 2. P. 125–137.
5. Jeng J.-T., Chuang C.-C., Su S.-F. Support vector interval regression networks for interval regression analysis // Fuzzy Sets and Systems. 2003. Vol. 138. Iss. 2. P. 283–300. [https://doi.org/10.1016/S0165-0114\(02\)00570-5](https://doi.org/10.1016/S0165-0114(02)00570-5).
6. Tahmasebi P., Hezarkhani A. A hybrid neural networks-fuzzy logic-genetic algorithm for grade estimation // Computers & Geosciences. 2012. Vol. 42. P. 18–27. <https://doi.org/10.1016/j.cageo.2012.02.004>.
7. Klir G., Yuan B. Fuzzy sets and fuzzy logic: theory and applications. New Jersey: Prentice Hall, 1995. 574 p.
8. Kaydani H., Mohebbi A., Baghaie A. Neural fuzzy system development for the prediction of permeability from wireline data based on fuzzy clustering // Petroleum Science and Technology. 2012. Vol. 30. Iss. 19. P. 2036–2045. <https://doi.org/10.1080/10916466.2010.531345>.
9. Press W. H., Teukolsky S. A., Vetterling W. T., Flannery B. P. Numerical recipes. The art of scientific computing. New York: Cambridge University Press, 2007. 1235 p.
10. Trontl K., Šmuc T., Pevc D. Support vector regression model for the estimation of γ -ray buildup factors for multi-layer shields // Annals of Nuclear Energy. 2007. Vol. 34. Iss. 12. P. 939–952. <https://doi.org/10.1016/j.anucene.2007.05.001>.
11. Gholami R., Shahraki A. R., Jamali Paghaleh M. Prediction of hydrocarbon reservoirs permeability using support vector machine // Mathematical Problems in Engineering. 2012. <https://doi.org/10.1155/2012/670723>.
12. Семькин М. В., Шакирова Э. В. Исследование по подбору эффективных деэмульгаторов при обезвоживании нефтей Восточной Сибири // 60 лет снимкам обратной стороны Луны: материалы Всерос. науч.-практ. конф. Иркутск: Изд-во ИРНИТУ, 2019. С. 76–81.
13. Gaisina L. M., Mikhailovskaya I. M., Khairullina N. G., Pilipenko L. M., Shakirova E. V. Features of the formation of the corporate identity of the staff // Biosciences Biotechnology Research Asia. 2015. Vol. 12. Iss. 3. P. 2543–2555. <https://doi.org/10.13005/bbra/1934>.
14. Averkina E. V., Shakirova E. V. Specifics of drilling wells in the abnormally-high-pressure rock beds in the oil-and-gas fields of Eastern Siberia // IOP Conference. Series: Earth and Environmental Science. 2019. Vol. 229. P. 012032. <https://doi.org/10.1088/1755-1315/229/1/012032>.
15. Белозерова О. В., Коваленко В. В., Шакирова Э. В. Исследование состава и свойств нефти Ичѣдинского месторождения // Известия вузов. Прикладная химия и биотехнология. 2020. Т. 10. № 3. С. 522–528. <https://doi.org/10.21285/2227-2925-2020-10-3-522-528>.
16. Аверкина Е. В., Шакирова Э. В., Николаева М. Б., Климова А. А. Сравнительный анализ реагентов-ингибиторов набухания глинистых отложений, применяемых на месторождениях Восточной Сибири // Известия Томского политехнического университета. Инжиниринг георесурсов. 2020. Т. 331. № 12. С. 138–145. <https://doi.org/10.18799/24131830/2020/12/2947>.
17. Gorokhova A. E., Gaisina L. M., Gareev E. S., Shutov N. V., Shakirova E. V. Application of coaching methods at agricultural and industrial enterprises to improve the quality of young specialists' adaptation // Quality – Access to Success. 2018. Vol. 19. Iss. 164. P. 103–108.
18. Gaisina L. M., Mikhaylovskaya I. M., Khairullina N. G., Ustinova O. V., Shakirova E. V. The role of the media in the spiritual and moral evolution of society // Mediterranean Journal of Social Sciences. 2015. Vol. 6. Iss. 5. P. 93–101. <https://doi.org/10.5901/mjss.2015.v6n5s2p93>.
19. Gaisina L. M., Dorozhkin Yu. N., Iakupova G. A., Rasuleva I. V., Dallakian G. R., Shakirova E. V. Reflection of contemporary socio-cultural factors on young rural family as a problem of rural development. A study case-the Republic of Bashkortostan // Scientific Papers. Series: Management, Economic Engineering in Agriculture and Rural Development. 2018. Vol. 18. Iss. 3. P. 131–138.



20. Шакирова Э. В., Семькин М. В., Александров А. А., Брыжеватых Н. В. Современные методы по подбору деэмульгаторов при обезвоживании нефтей

Восточной Сибири // Проблемы сбора, подготовки и транспорта нефти и нефтепродуктов. 2021. № 3. С. 36–44. <https://doi.org/10.17122/ntj-oil-2021-3-36-44>.

References

- Lippmann R. P. An introduction to computing with neural nets. *IEEE ASSP Magazine*. 1987;4(2):4-22.
- Hinton G. E., Osindero S., Teh Y.-W. A fast learning algorithm for deep belief nets. *Neural Computation*. 2006;18(7):1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>.
- Rammy M. H., Abdurraheem A. Automated history matching using combination of adaptive neuro fuzzy system (ANFIS) and differential evolution algorithm. In: *SPE Large Scale Computing and Big Data Challenges in Reservoir Simulation Conference and Exhibition*. Istanbul; 2014. SPE-172992-MS.
- Ben-Hur A., Horn D., Siegelmann H. T., Vapnik V. Support vector clustering. *Journal of Machine Learning Research*. 2001;2:125-137.
- Jeng J.-T., Chuang C.-C., Su S.-F. Support vector interval regression networks for interval regression analysis. *Fuzzy Sets and Systems*. 2003;138(2):283-300. [https://doi.org/10.1016/S0165-0114\(02\)00570-5](https://doi.org/10.1016/S0165-0114(02)00570-5).
- Tahmasebi P., Hezarkhani A. A hybrid neural networks-fuzzy logic-genetic algorithm for grade estimation. *Computers & Geosciences*. 2012;42:18-27. <https://doi.org/10.1016/j.cageo.2012.02.004>.
- Klir G., Yuan B. *Fuzzy sets and fuzzy logic: theory and applications*. New Jersey: Prentice Hall; 1995. 574 p.
- Kaydani H., Mohebbi A., Baghaie A. Neural fuzzy system development for the prediction of permeability from wireline data based on fuzzy clustering. *Petroleum Science and Technology*. 2012;30(19):2036-2045. <https://doi.org/10.1080/10916466.2010.531345>.
- Press W. H., Teukolsky S. A., Vetterling W. T., Flannery B. P. *Numerical recipes. The art of scientific computing*. New York: Cambridge University Press; 2007. 1235 p.
- Trontl K., Šmuc T., Pevec D. Support vector regression model for the estimation of γ -ray buildup factors for multi-layer shields. *Annals of Nuclear Energy*. 2007;34(12):939-952. <https://doi.org/10.1016/j.anucene.2007.05.001>.
- Gholami R., Shahraki A. R., Jamali Paghaleh M. Prediction of hydrocarbon reservoirs permeability using support vector machine. *Mathematical Problems in Engineering*. 2012. <https://doi.org/10.1155/2012/670723>.
- Semykin M. V., Shakirova E. V. Research on selection of effective demulsifiers for dehydration of Eastern Siberian oils. In: *60 let snimkam obratnoi storony Luny: materialy Vserossiiskoi nauchno-prakticheskoi konferentsii = 60th anniversary of images of the back side of the Moon: materials of the All-Russian scientific and practical conference*. Irkutsk: Irkutsk National Research Technical University; 2019. p.76–81. (In Russ.).
- Gaisina L. M., Mikhailovskaya I. M., Khairullina N. G., Pilipenko L. M., Shakirova E. V. Features of the formation of the corporate identity of the staff. *Biosciences Biotechnology Research Asia*. 2015;12(3):2543-2555. <https://doi.org/10.13005/bbra/1934>.
- Averkina E. V., Shakirova E. V. Specifics of drilling wells in the abnormally-high-pressure rock beds in the oil-and-gas fields of Eastern Siberia. *IOP Conference. Series: Earth and Environmental Science*. 2019;229:012032. <https://doi.org/10.1088/1755-1315/229/1/012032>.
- Belozerova O. V., Kovalenko V. V., Shakirova E. V. Study of the composition and properties of crude oil mined at the Ichyodinskoye field. *Izvestiya vuzov. Prikladnaya khimiya i biotekhnologiya = Proceedings of Universities. Applied Chemistry and Biotechnology*. 2020;10(3):522-528. (In Russ.). <https://doi.org/10.21285/2227-2925-2020-10-3-522-528>.
- Averkina E. V., Shakirova E. V., Nikolaeva M. B., Klimova A. A. Comparative analysis of reagents-inhibitors of swelling of clay deposits used in Eastern Siberia. *Izvestiya Tomskogo politekhnicheskogo universiteta. Inzhiniring geosursov = Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*. 2020;331(12):138-145. (In Russ.). <https://doi.org/10.18799/24131830/2020/12/2947>.
- Gorokhova A. E., Gaisina L. M., Gareev E. S., Shutov N. V., Shakirova E. V. Application of coaching methods at agricultural and industrial enterprises to improve the quality of young specialists' adaptation. *Quality – Access to Success*. 2018;19(164):103-108.
- Gaisina L. M., Mikhaylovskaya I. M., Khairullina N. G., Ustinova O. V., Shakirova E. V. The role of the media in the spiritual and moral evolution of society. *Mediterranean Journal of Social Sciences*. 2015;6(5):93-101. <https://doi.org/10.5901/mjss.2015.v6n5s2p93>.
- Gaisina L. M., Dorozhkin Yu. N., Iakupova G. A., Rasuleva I. V., Dallakian G. R., Shakirova E. V. Reflection of contemporary socio-cultural factors on young rural family as a problem of rural development. A study case-the Republic of Bashkortostan. *Scientific Papers. Series: Management, Economic Engineering in Agriculture and Rural Development*. 2018;18(3):131-138.
- Shakirova E. V., Semykin M. V., Aleksandrov A. A., Bryzhevatykh N. V. Modern methods for the selection of effective demulgators for oil dehydration in Eastern Siberia. *Problemy sbora, podgotovki i transporta nefii i nefteproduktov = Problems of Gathering, Treatment and Transportation of Oil and Oil Products*. 2021;3:36-44. (In Russ.). <https://doi.org/10.17122/ntj-oil-2021-3-36-44>.



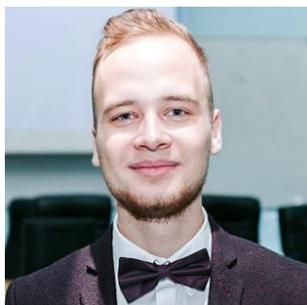
Информация об авторах / Information about the authors



Шакирова Эльвира Венеровна,
кандидат политических наук, доцент,
доцент кафедры нефтегазового дела,
Институт недропользования,
Иркутский национальный исследовательский технический университет,
г. Иркутск, Россия,
viva160@mail.ru,
<https://orcid.org/0000-0003-0605-2920>.
Elvira V. Shakirova,
Cand. Sci. (Polit.), Associate Professor,
Associate Professor of the Department of Oil and Gas Engineering,
Institute of Subsoil Use,
Irkutsk National Research Technical University,
Irkutsk, Russia,
viva160@mail.ru,
<https://orcid.org/0000-0003-0605-2920>.



Александров Александр Андреевич,
студент,
Политехническая школа,
Тюменский государственный университет,
г. Тюмень, Россия,
kavabanga1999@mail.ru,
<https://orcid.org/0000-0001-6925-762X>.
Aleksandr A. Aleksandrov,
Student,
Polytechnic School,
University of Tyumen,
Tyumen, Russia,
kavabanga1999@mail.ru,
<https://orcid.org/0000-0001-6925-762X>.



Семькин Михаил Вячеславович,
студент,
Институт недропользования,
Иркутский национальный исследовательский технический университет,
г. Иркутск, Россия,
siemykin99@mail.ru,
<https://orcid.org/0000-0002-6134-1656>.
Mikhail V. Semykin,
Student,
Institute of Subsoil Use,
Irkutsk National Research Technical University,
Irkutsk, Russia,
siemykin99@mail.ru,
<https://orcid.org/0000-0002-6134-1656>.

Вклад авторов / Contribution of the authors

Все авторы сделали эквивалентный вклад в подготовку публикации.
The authors contributed equally to this article.

Конфликт интересов / Conflict of interests

Авторы заявляют об отсутствии конфликта интересов.
The authors declare no conflicts of interests.



*Все авторы прочитали и одобрили окончательный вариант рукописи.
The final manuscript has been read and approved by all the co-authors.*

Информация о статье / Information about the article

Статья поступила в редакцию 27.08.2021; одобрена после рецензирования 14.10.2021; принята к публикации 18.11.2021.

The article was submitted 27.08.2021; approved after reviewing 14.10.2021; accepted for publication 18.11.2021.