



Научная статья

УДК 552.578.2+519.677+004.032.26

<https://elibrary.ru/pjemfo><https://doi.org/10.21285/2686-9993-2023-46-2-226-233>

Прогнозирование аварий на погружном насосном оборудовании с использованием методов искусственного интеллекта

Э.В. Шакирова^а, М.В. Семькин^б^аИркутский национальный исследовательский технический университет, г. Иркутск, Россия^бТюменский государственный университет, г. Тюмень, Россия

Резюме. Как известно, в процессе работы электрических погружных насосов собираются и обрабатываются большие объемы данных. Для оптимизации работы операторов центра управления разработкой рекомендуется использовать автоматизированную систему предупреждения осложнений. Так операторам удастся своевременно получать информацию о возможных сбоях в работе оборудования, что, в свою очередь, позволит увеличить срок службы данного оборудования и снизить операционные затраты на ремонт. Целью представленного исследования являлась разработка модели для прогнозирования аварий на погружном насосном оборудовании с использованием методов искусственного интеллекта. Для выявления наиболее точной модели в данной работе приведено сравнение следующих методов прогнозирования: метода ближайших соседей и метода построения линейного классификатора. Представленная корреляция создана на основе 30 параметров с 272 скважин месторождения Восточной Сибири. Ее использование позволило без ошибок спрогнозировать сбой и осложнения в работе насосного оборудования в зависимости от газового фактора и частоты. Таким образом, разработанная модель может быть использована предприятиями нефтегазодобывающей отрасли для прогнозирования сбоев и аварий в работе погружного насосного оборудования. Проведенное исследование показывает, что точность прогнозирования искомого параметра в разработанной модели искусственного интеллекта превосходит результаты обычных статистических методов. Также модель может быть полезна в перспективе оптимизации процессов при планировании и разработке месторождений. Искусственный интеллект является наилучшим методом прогнозирования аварий на погружном оборудовании, благодаря высокой скорости и точности когнитивные технологии широко применяются в обработке больших данных.

Ключевые слова: погружное насосное оборудование, искусственный интеллект, прогнозирование, коэффициент корреляции, средняя абсолютная ошибка

Для цитирования: Шакирова Э.В., Семькин М.В. Прогнозирование аварий на погружном насосном оборудовании с использованием методов искусственного интеллекта // Науки о Земле и недропользование. 2023. Т. 46. № 2. С. 226–233. <https://elibrary.ru/pjemfo>, <https://doi.org/10.21285/2686-9993-2023-46-2-226-233>.

Original article

Submersible pumpset failure prediction using artificial intelligence methods

Elvira V. Shakirova^а, Mikhail V. Semykin^б^аIrkutsk National Research Technical University, Irkutsk, Russia^бUniversity of Tyumen, Tyumen, Russia

Abstract. It is well-known that large amounts of data are collected and processed during the operation of electric submersible pumps. To optimize the work of mining control center operators, it is recommended to use an automated emergency prevention system. In this way, operators will be able to receive timely information about possible equipment failures, which in its turn will increase the service life of the equipment and reduce operating costs for repairs. The purpose of the present research is to develop a model predicting submersible pumping equipment failures using the method of artificial intelligence. To identify the most accurate model, the paper compares the following forecasting methods: the nearest neighbour



method and the linear classifier building method. The presented correlation was created on the basis of 30 parameters obtained from 272 wells of the Eastern Siberia field. Being used, it enabled error-free prediction of failures and complications in pumping equipment operation depending on the gas factor and frequency. Thus, the developed model can be used by oil and gas enterprises to predict failures and accidents in the operation of submersible pumping equipment. The conducted study shows that the prediction accuracy of the required parameter in the developed artificial intelligence model exceeds the results of conventional statistical methods. The model also can be useful for future optimization of processes when field planning and developing. Artificial intelligence is the best prediction method of submersible pumping equipment failures, due to its high speed and accuracy, cognitive technologies are widely used in big data processing.

Keywords: submersible pumpset, artificial intelligence, prediction, correlation coefficient, mean absolute error

For citation: Shakirova E.V., Semykin M.V. Submersible pumpset failure prediction using artificial intelligence methods. *Nauki o Zemle i nedropol'zovanie = Earth sciences and subsoil use*. 2023;46(2):226-233. (In Russ.). <https://elibrary.ru/pjemfo>, <https://doi.org/10.21285/2686-9993-2023-46-2-226-233>.

Введение

В настоящее время одной из приоритетных задач, стоящих перед нефтегазодобывающими компаниями, является повышение эффективности операционной деятельности. Для достижения данной цели, в свою очередь, необходимо оптимизировать все процессы, протекающие в компании. Наиболее результативным методом оптимизации является применение искусственного интеллекта [1].

Искусственный интеллект – это способность имитации человеческого интеллекта при помощи компьютерных систем. Данный метод позволяет выполнять следующие задачи:

- обучение, обработка информации;
- применение изученной информации для принятия определенных решений;
- исправление встречающихся в работе ошибок, самокоррекция.

Наиболее капиталоемкой статьей расходов в нефтегазодобыче является этап строительства скважин: на него приходится порядка 40 % всех привлеченных инвестиций [2, 3]. При совершенствовании технологий сбора и обработки больших данных, содержащих информацию о жизненном цикле скважин, могут быть разработаны системы предупреждения и предотвращения возможных аварий. Данные системы позволяют выявить определенные закономерности и степень их влияния при помощи технологий искусственного интеллекта [4]. Так, например, в процессе работы электрических погружных насосов используются как внутрискважинные, так и поверхностные каналы для передачи данных в локальный центр управления разработкой месторождения. В зависимости от типа используемых скважинных датчиков можно отсле-

дить следующие параметры: давление и температуру на приеме насоса, температуру обмотки погружного электродвигателя, температуру моторного масла и величину осевых вибраций [5]. Помимо этого, данная система в режиме реального времени позволит проводить мониторинг следующих параметров на устье скважины: поверхностный расход, давление в трубопроводе, давление в обсадной колонне, частоту, удельное сопротивление кабеля и фазное напряжение [6, 7].

Таким образом, в случае использования автоматизированной системы предупреждения осложнений предприятию удастся заблаговременно учесть возможные сбои в работе оборудования, тем самым увеличить срок службы данного оборудования и снизить эксплуатационные расходы на ремонт [8, 9].

Материалы и методы исследования

В качестве исходных данных для анализа были использованы промысловые данные с одного из месторождений Восточной Сибири: технология добычи и параметры работы электроцентробежного насоса, текущие параметры разработки, PVT-свойства и энергопотребление (табл. 1). Перед началом работы необходимо подготовить исходную выборку. Для этого требуется проверить данные на наличие аномальных значений или же на несоответствия типам данных, а также при необходимости удалить строки с недостающими данными [10]. В дальнейшем данную выборку необходимо поделить на тренировочную, по которой будут определяться зависимости и прогнозироваться показатели, и тестовую, по которой будет осуществляться проверка натренированной модели [11].



Таблица 1. Данные с месторождения Восточной Сибири
Table 1. Data from the Eastern Siberia field

Скважина	Параметры работы электроцентробежного насоса				...	Состояние
	Номинальный напор, м	Количество ступеней электроцентробежного насоса	Частота, Гц	Мощность погружного электродвигателя, кВт	...	
X ₁	2050	334	55	56	...	В работе
X ₂	1850	329	55	45	...	В работе
X ₃	1850	334	40	32	...	В работе
X ₄	1500	347	57	56	...	В работе
X ₅	1800	326	40	32	...	В работе
X ₆	2204	470	46,5	45	...	в работе
X ₇	2204	470	45,7	45	...	В работе
X ₈	1960	308	53	45	...	Остановлена
...	...	...	...	...	...	...
X ₂₇₂	1500	290	57	32	...	В работе

Согласно исходной выборке, средний показатель обводненности скважинной продукции составляет 23,5 %, при этом минимальное и максимальное значения равны 0 и 93 % соответственно. В свою очередь, среднее содержание механических примесей составляет 140,3 мг/л с минимальным значением 16 мг/л и максимальным значением 758 мг/л.

После того, как выборка была подготовлена, необходимо провести селекцию признаков таблицы с помощью метода ExtraTreesClassifier и установить столбцы с наиболее выраженными связями [12, 13]. В данном случае таковыми оказались признаки «Газовый фактор» и «Частота» (табл. 2).

Далее необходимо натренировать модели искусственного интеллекта. Для этого всю выборку нужно разделить на две равные части по 136 строк в каждой [14]. Искомый парамет-

ром, который будет сопоставляться с прогнозными показателями, является столбец «Состояние». Именно по данному критерию будет проведено сравнение показателей натренированной модели. В качестве классификации категориального признака «Состояние» воспользуемся двумя методами: методом ближайших соседей (*англ.*: *k*-nearest neighbors algorithm, *k*-NN) и методом построения линейного классификатора.

Первый метод включает в себя оценивание сходств объектов, то есть объект принадлежит к тому классу, к которому относятся ближайшие к нему объекты тренировочной выборки. Данный метод опирается на гипотезу компактности, которая гласит, что если степень сходства объектов введена удовлетворительно, то схожие объекты преобладающим образом лежат в одном классе. В таком

Таблица 2. Данные, полученные в ходе селекции признаков
Table 2. Data obtained from characteristic selection

Признак	Степень влияния
Состояние	0,64863
Газовый фактор	0,078427
Частота	0,028361
Дебит жидкости	0,018052
Содержание мехпримесей	0,015006
Коэффициент подачи насоса	0,014784
Вязкость воды в пластовых условиях	0,01346
Буферное давление	0,011049
Давление в линии	0,010935



случае граница между классами характеризуется простой формой, а сами классы образуют компактно локализованные области в пространстве объектов. Данный метод настраиваемый: за количество принимаемых ближайших соседей можно взять любое число $k \geq 1$.

Второй метод основан на построении линейной разделяющей поверхности. При наличии двух классов разделяющей поверхностью является гиперплоскость, которая и делит все признаки на два полупространства.

Для проверки качества работы искусственного интеллекта необходимо применить метод crosstab библиотеки Pandas [3, 7, 15, 16]. Данный метод выводит матрицу ошибок, на которой наглядно видно количество случаев верного или же неверного определения аварий [4, 5, 17, 18]. Искусственный интеллект сработал отлично, если он правильно соотнес все скважины тестовой выборки: 5 позиций «остановлена» и 131 позицию «в работе».

Результаты исследования

Проверка метода ближайших соседей на тестовой модели показала, что данный метод позволяет идеально отобразить все позиции «остановлена» и «в работе» при количестве ближайших соседей $k = 1$ (рис. 1).

При увеличении параметра k качество работы искусственного интеллекта падает, что говорит о низкой эффективности используемого метода. Так, например, при $k = 3$ искусственный интеллект определил только 3 позиции «остановлена» вместо заданных 5 (рис. 2).

Метод построения линейного классификатора показал меньшую точность в сравнении с предыдущим методом [7]. Так, искусственный интеллект определил 5 позиций «остановлена», но они не совпадают с действительными скважинами из исходных данных (рис. 3). Данный метод не удовлетворяет условиям подбора ввиду низкой эффективности [19, 20].




Рис. 1. Результаты обучения модели методом ближайших соседей при $k = 1$
Fig. 1. Results of model training by the nearest neighbor method when $k = 1$




Рис. 2. Результаты обучения модели методом ближайших соседей при $k = 3$
Fig. 2. Results of model training by the nearest neighbor method when $k = 3$




Рис. 3. Результаты обучения модели методом построения линейного классификатора
Fig. 3. Results of model training by the linear classifier building method

В ходе исследования было выявлено, что метод ближайших соседей при $k = 1$ смог предсказать остановку скважины в 100 % случаев [17]. Второй же метод не смог предсказать остановки скважин и принял 5 работающих скважин за остановленные (рис. 4).

Обсуждение полученных результатов

В ходе селекции признаков методом Extra-TreesClassifier были определены ключевые влияющие параметры: газовый фактор и частота. Именно на данных параметрах и базируется определение состояния работы погружного насосного оборудования. Разработанная корреляция искусственного интеллекта, базирующаяся на методе ближайших соседей, показала высокую эффективность при работе с тестовой выборкой. В дальнейшем применение такой корреляции на производственных объектах позволит заблаговременно определять сбои и аварии в работе скважины, тем самым увеличивать межремонтный период, а также срок службы исполь-

зуемого оборудования, что, в свою очередь, приведет к снижению эксплуатационных расходов на ремонт.

Заключение

Таким образом, при полномасштабном введении технологий искусственного интеллекта могут быть достигнуты все стоящие перед нефтегазодобывающими компаниями задачи, связанные с повышением эффективности производственных процессов. В то же время использование данных технологий позволит повысить уровень управления процессами по нефте- и газодобыче одновременно со снижением уровня влияния человеческого фактора.

В ходе проведенного исследования была разработана модель искусственного интеллекта для прогнозирования аварий как функции, зависящей от газового фактора и частоты. На основании полученных в ходе работы данных можно сделать следующие выводы:

1. Метод ближайших соседей является наиболее точной моделью искусственного интел-

Состояние в работе остановлена			Состояние в работе остановлена		
Predicted			Predicted		
в работе	131	0	в работе	126	5
остановлена	0	5	остановлена	5	0
a			b		

Рис. 4. Матрица ошибок:
a – метода ближайших соседей; b – метода построения линейного классификатора

Fig. 4. Error matrix:
a – the nearest neighbour method; b – the linear classifier building method



кта, которая способна предсказать сбои и осложнения в работе оборудования без ошибок.

2. Метод построения линейного классификатора в данном случае обладает меньшей эффективностью и не может в полной мере удовлетворить условиям подбора.

3. Разработанная модель может быть ис-

пользована на производстве для прогнозирования аварий в работе погружного насосного оборудования с высоким показателем точности. Для увеличения данного показателя необходимо дополнить тренировочную модель остальными промысловыми показателями и оценить степень их влияния.

Список источников

1. Черников А.Д., Еремин Н.А., Столяров В.Е., Сбоев А.Г., Семенова-Чашина О.К., Фицнер Л.К. Применение методов искусственного интеллекта для выявления и прогнозирования осложнений при строительстве нефтяных и газовых скважин: проблемы и основные направления решения // Георесурсы. 2020. Т. 22. № 3. С. 87–96. <https://elibrary.ru/ornybd>, <https://doi.org/10.18599/grs.2020.3.87-96>.
2. Дмитриевский А.Н., Дуплякин В.О., Еремин Н.А., Капранов В.В. Алгоритм создания нейросетевой модели для классификации в системах предупреждения осложнений и аварийных ситуаций при строительстве нефтяных и газовых скважин // Датчики и системы. 2019. № 12. С. 3–10. <https://elibrary.ru/nkrfen>, <https://doi.org/10.25728/datsys.2019.12.1>.
3. 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>.
4. Tahmasebi P., Hezarkhani 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>.
5. 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>.
6. 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://elibrary.ru/ridjiu>, <https://doi.org/10.17122/ntj-oil-2021-3-36-44>.
7. Ben-Hur A., Horn D., Siegelmann H.T., Vapnik V. Support vector clustering // Journal of Machine Learning Research. 2001. Vol. 2. P. 125–137. <https://doi.org/10.4249/scholarpedia.5187>.
8. 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.
9. 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://elibrary.ru/vrenyh>, <https://doi.org/10.21285/2686-9993-2021-44-4-408-416>.
10. 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. 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. P. 670723. <https://doi.org/10.1155/2012/670723>.
12. 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>.
13. 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://elibrary.ru/yzjzxy>, <https://doi.org/10.21285/2227-2925-2020-10-3-522-528>.
14. 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://elibrary.ru/teeamu>, <https://doi.org/10.18799/24131830/2020/12/2947>.
15. Lippmann R.P. An introduction to computing with neural nets // IEEE ASSP Magazine. 1987. Vol. 4. Iss. 2. P. 4–22.
16. Rammay M.H., Abdullaheem 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 held. Istanbul, 2014. P. 172992. <https://doi.org/10.2118/172992-MS>.
17. Jeng J.-T., Chuang C.-C., Su S.-F. Support vector interval regression networks for interval re-gression 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).
18. Klir G.J., Yuan B. Fuzzy sets and fuzzy logic: theory and applications. Upper Saddle River: Prentice Hall PTR, 1995. 574 p.
19. Fink J. Petroleum engineers guide to oil field chemicals and fluids. Waltham: Gulf Professional Publishing,



2011. 808 p.

20. Akangbou H.N., Burby M., Nasr G. Effectively optimizing production of horizontal wells in homogeneous oil

reservoirs // *Journal of Petroleum Science and Engineering*. 2017. Vol. 150. P. 128–136. <https://doi.org/10.1016/j.petrol.2016.12.005>.

References

1. Chernikov A.D., Eremin N.A., Stolyarov V.E., Sboev A.G., Semenova-Chashchina O.K., Fitsner L.K. Application of artificial intelligence methods for identifying and predicting complications in the construction of oil and gas wells: problems and solutions. *Georesursy = Georesources*. 2020;22(3):87-96. (In Russ.). <https://elibrary.ru/ornybd>, <https://doi.org/10.18599/grs.2020.3.87-96>.
2. Dmitrievsky A.N., Duplyakin V.O., Eremin N.A., Kapranov V.V. Algorithm for creating a neural network model for classification in systems for preventing complications and emergencies in construction of oil and gas wells. *Datchiki & Systemi = Sensors & Systems*. 2019;12:3-10. (In Russ.). <https://elibrary.ru/nkrfen>, <https://doi.org/10.25728/datsys.2019.12.1>.
3. 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>.
4. Tahmasebi P., Hezarkhani 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>.
5. 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>.
6. 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 nefti i nefteproduktov = Problems of gathering, treatment and transportation of oil and oil products*. 2021;3:36-44. (In Russ.). <https://elibrary.ru/ridjiu>, <https://doi.org/10.17122/ntj-oil-2021-3-36-44>.
7. Ben-Hur A., Horn D., Siegelmann H.T., Vapnik V. Support vector clustering. *Journal of Machine Learning Research*. 2001;2:125-137. <https://doi.org/10.4249/scholarpedia.5187>.
8. 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.
9. 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://elibrary.ru/vrenyh>, <https://doi.org/10.21285/2686-9993-2021-44-4-408-416>.
10. 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>.
11. Gholami R., Shahraki A.R., Jamali Paghaleh M. Prediction of hydrocarbon reservoirs permeability using support vector machine // *Mathematical Problems in Engineering*. 2012:670723. <https://doi.org/10.1155/2012/670723>.
12. 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>.
13. Belozeroval 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://elibrary.ru/yzyzxy>, <https://doi.org/10.21285/2227-2925-2020-10-3-522-528>.
14. 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 georesursov = Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*. 2020;331(12):138-145. (In Russ.) <https://elibrary.ru/teeamu>, <https://doi.org/10.18799/24131830/2020/12/2947>.
15. Lippmann R.P. An introduction to computing with neural nets. *IEEE ASSP Magazine*. 1987;4(2):4-22.
16. Rammay M.H., Abdulraheem 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 held*. Istanbul; 2014, p. 172992. <https://doi.org/10.2118/172992-MS>.
17. 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).
18. Klir G.J., Yuan B. *Fuzzy sets and fuzzy logic: theory and applications*. Upper Saddle River: Prentice Hall PTR; 1995. 574 p.
19. Fink J. *Petroleum engineers guide to oil field chemicals and fluids*. Waltham: Gulf Professional Publishing; 2011. 808 p.
20. Akangbou H.N., Burby M., Nasr G. Effectively optimizing production of horizontal wells in homogeneous oil reservoirs. *Journal of Petroleum Science and Engineering*. 2017; 150:128-136. <https://doi.org/10.1016/j.petrol.2016.12.005>.



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>



Семькин Михаил Вячеславович,
студент,
Передовая инженерная школа,
Тюменский государственный университет,
г. Тюмень, Россия,
siemykin99@mail.ru
<https://orcid.org/0000-0002-6134-1656>
Mikhail V. Semykin,
Student,
Advanced Engineering School,
University of Tyumen,
Tyumen, 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 14.03.2023; одобрена после рецензирования 11.05.2023; принята к публикации 26.05.2023.

The article was submitted 14.03.2023; approved after reviewing 11.05.2023; accepted for publication 26.05.2023.