

ОПРЕДЕЛЕНИЕ ЗОН ТЕХНОЛОГИЧЕСКОГО ЗАКИСЛЕНИЯ НА УРАНОВЫХ МЕСТОРОЖДЕНИЯХ КАЗАХСТАНА С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

К. Абрамов¹, Н. Р. Юничева^{1,2*} к.т.н., доцент, Я. И. Кучин^{1,3} Е. Мухамедиева¹

¹Институт информационных и вычислительных технологий МНВО РК, 050010, Алматы

²Алматинский Университет энергетики и связи им. Г. Даукеева, 050013, Алматы

³КазННТУ им. К.И. Сатпаева, 050013, Алматы,

E-mail: ykuchin@mail.ru, naduni@mail.ru

Определение зон технологического закисления на урановых месторождениях во время выщелачивания необходимо для точного контроля и оптимизации процесса извлечения урана. Неверное определение зоны технологического закисления может привести к избыточному использованию кислотных реагентов, что не только увеличит затраты, но также может вызвать нежелательные экологические последствия. В работе предложен подход к решению вопросов, связанных с ручным определением зон технологического закисления на урановых месторождениях в Казахстане. Подход включает в себя изучение алгоритмов машинного обучения для автоматизации выявления этих критически важных зон. Применение моделей искусственной нейронной сети (ANN) и модели экстремального градиентного бустинга (XGB), показало свою эффективность в автоматизации и улучшении идентификации этих важных зон при отработке месторождений урана методом подземного скважинного выщелачивания. Так, точность выделения интервалов закисления по метрике F1-score для модели ANN составляет 0,75, а для модели XGB составляет 0,80.

Ключевые слова: машинное обучение, добыча урана, зона технологического закисления, подземное скважинное выщелачивание, искусственные нейронные сети (Artificial Neuron Network / ANN), экстремальный градиентный бустинг (Extreme Gradient Boosting / XGB).

Поступила: 27.02.24

DOI: 10.54668/2789-6323-2024-113-2-67-80

ВВЕДЕНИЕ

Ядерная энергетика, как известно, играет важную роль в развитии современной промышленности. Её преимущества многообразны, начиная от низкого углеродного следа до способности предоставлять энергию крупномасштабно без использования больших объемов ископаемого топлива. Энергетическая плотность урана, основного топлива для ядерных реакторов, позволяет рассматривать ядерную энергию как основу в переходе к более чистому и экологичному производству.

Республика Казахстан является одним из ключевых участников на урановом рынке по добыче ископаемого урана, который служит основным сырьем для производства ядерной энергии. Месторождения урана существенно способствуют её экономическому росту и удовлетворяют растущему глобальному

спросу на ядерную энергию.

Метод подземного скважинного выщелачивания - основной способ добычи урана в Казахстане (Петров Н., 1995), (Петров Н., Язиков В.Г, 2014). Метод включает в себя введение кислотного раствора непосредственно в рудное тело, что позволяет растворять уран в естественной среде (Перельман А. И., 1980). Значимость этого метода в его потенциале - уменьшить воздействие на окружающую среду (Евсеева Л. С., 1962). Вместе с тем, определение зон технологического закисления пластов в пределах применения подземного скважинного выщелачивания, представляет собой значительные трудности.

Технологическое закисление в методе подземного выщелачивания на месторождениях урана – это процесс изменения химического состава раствора,

используемого для выщелачивания металла из руды. В методе выщелачивания на месторождениях урана используется химическая реакция с применением кислоты для выщелачивания урана непосредственно из зоны месторождения. Формирование зон технологического закисления происходит в результате реакции кислоты с минералами в горных породах. Кислотное воздействие вызывает химические изменения в окружающей среде, приводя к образованию растворов, богатых ураном

(Перельман А. И., 1965).

Определение зон технологического закисления в методе подземного выщелачивания осуществляется с использованием различных методов каротажа. Хорошим способом визуального определения зон технологического закисления является занижение кривой каротажа электрических сопротивлений. Пример зон технологического закисления в скважине представлен на рисунке 1.

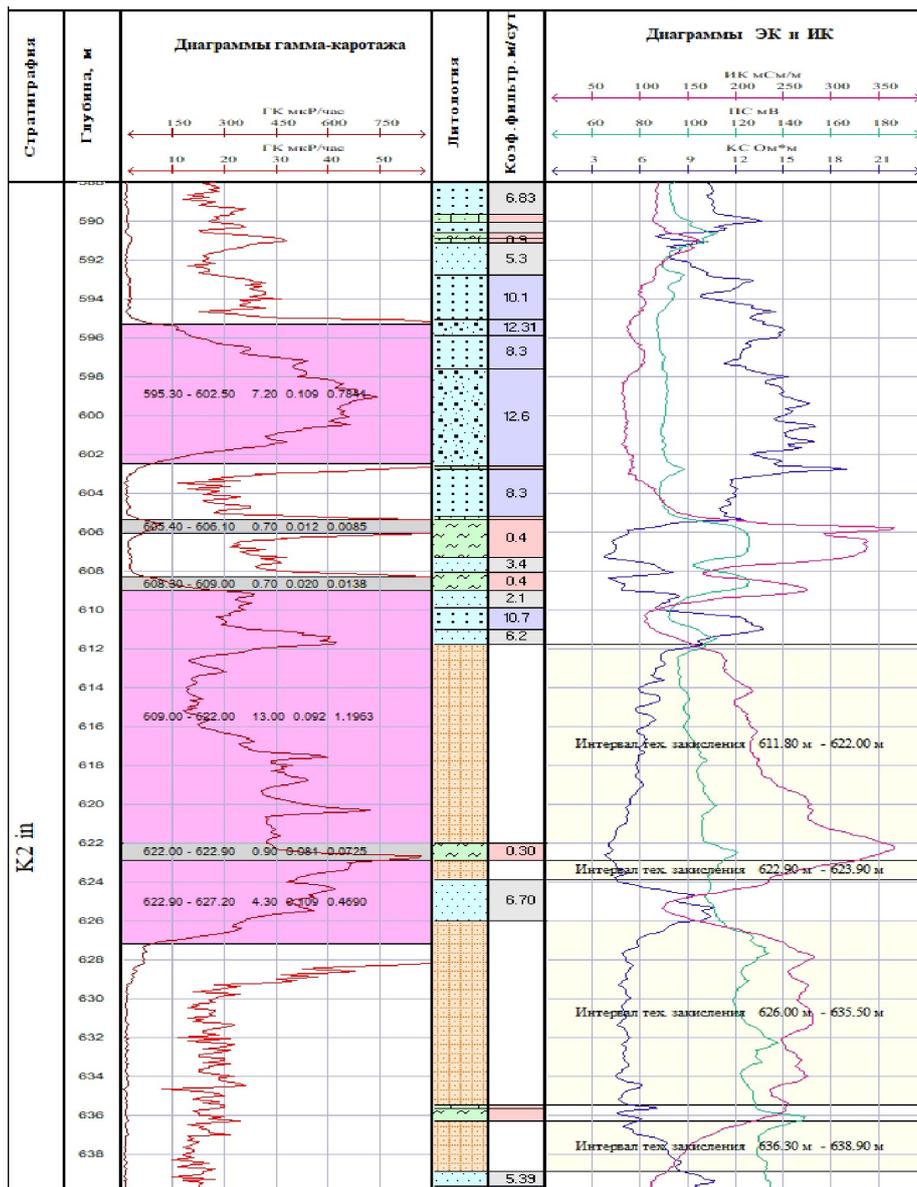


Рис.1. Пример зон технологического закисления в скважине

Геологическая и гидрогеологическая сложность процесса выщелачивания, в сочетании с динамичной природой технологического закисления, делает точное ручное определение невероятно сложным (Helbig K., Treitel S., 2001). Существующие программные решения обнаруживают ограничения в предоставлении

всеохватывающего и автоматизированного понимания этих критических зон.

Определение зон технологического закисления на урановых месторождениях во время выщелачивания необходимо для точного контроля и оптимизации процесса извлечения урана. Зоны представляют собой

области, подвергшиеся воздействию кислотных реагентов, и их правильное выделение позволяет эффективно управлять ресурсами, сокращая издержки и минимизируя воздействие на окружающую среду.

Неверное определение зоны технологического закисления может привести к избыточному использованию кислотных реагентов, что не только увеличит затраты, но также может вызвать нежелательные экологические последствия. Недостовверное выделение этих зон также ведет к неверному определению коэффициента фильтрации пород, что может существенно снизить эффективность самого процесса выщелачивания.

В работе предложен подход к решению вопросов, связанных с ручным определением зон технологического закисления на урановых месторождениях в Казахстане. Предлагаемый подход включает в себя изучение алгоритмов машинного обучения для автоматизации выявления этих критически важных зон. На основе использования мощности алгоритмов машинного обучения, в работе показана возможность повышения точности и эффективности определения зон технологического закисления для устойчивого развития добычи урановых ресурсов в Казахстане.

Приложения машинного обучения (МО / ML) в геофизике давно привлекали значительное внимание. Внедрение алгоритмов машинного обучения в геофизику привело к смене парадигмы обработки и интерпретации данных и отражено в следующих публикациях (M. Van der Baan, C. Jutten, 2000), (L. Hai An, 2000.), (M.A. Сенилов, 2003), (S. Maiti, R. K. Tiwari, 2007), (D. Benaouda et al., 1999), (V. Tschannen et al., 2017), (S. Chikhi et al, 2007), (I. Bachri et al, 2019), (P. И. Мухамедиев, и др., 2015), (E. Н. Амиргалиев, 2013), (Yan Kuchin et al, 2017), (Mukhamediev R.I. et al, 2023), (Kuchin et al, 2023), (Наукин S.S., 1994).

Несмотря на достижения, сохраняются проблемы с предварительной обработкой и классификацией, что требует дальнейших исследований. Указанные исследования определяют детальный и контекстно-ориентированный подход к приложениям МО

в геофизике урана, что делает актуальным для исследовательской решени существующих пробелов для получения более надежных и точных результатов.

МАТЕРИАЛЫ И МЕТОДЫ

На первом этапе собраны данные с урановых месторождений в Южном Казахстане. Выделены данные каротажей из общей выборки в 68 скважинах, среди которых 42 обладают зонами технологического закисления. Данные для работы алгоритмов машинного обучения организованы в формате Microsoft Excel и импортированы из корпоративной базы данных. Набор данных включает три ключевых листа из XLS-файла.

Первый лист служит хранилищем каротажей в цифровом виде с шагом квантования в 10 сантиметров. Данные включают различные типы каротажей, каждый из которых предоставляет конкретную информацию о геологических формациях. К ним относятся ГК (Гамма Каротаж), КС (Кажущееся Сопротивление), ПС (Поляризация Самопроизвольная), КМ (Каварнометрия), ИК (индукционный каротаж) Для рудоносного горизонта записаны концентрации радия, предоставляя важные сведения о потенциальных урановых залежах.

Второй лист содержит данные литологии, классифицируя типы горных пород по проницаемости. Эта информация важна для понимания геологического строения и фильтрационных характеристик подземных образований. Здесь закодированы литологические различия, записаны коэффициенты фильтрации, давая представление о пористости и проницаемости подземных формаций. Также включены нормализованные значения для электрических каротажей, способствуя более глубокому пониманию проводящих свойств геологических образований.

Третий лист предоставляет географические координаты скважины. Эта информация фундаментальна для пространственного анализа и картографии урановых залежей.

Предварительная обработка данных играет ключевую роль в очистке и подготовке

набора данных для анализа методами машинного обучения. Этот этап является неотъемлемой для обеспечения чистоты и готовности набора данных для последующего анализа с помощью методов машинного обучения. Данные для каждой скважины загружены с фокусом на скважинах с наличием зон технологического закисления и без таких зон.

После загрузки данные преобразовываются для объединения наборов, содержащих зоны технологического закисления и не содержащих их в единый список для упрощенного анализа.

Из первого листа каждого файла извлечены ключевые данные, такие как номер скважины, информация о глубине, данные о

рудных пересечениях, каротажи ГК, КС, ПС и КМ. Для рудоносного горизонта также извлекались значения концентрации радия.

Второй лист предоставил следующие данные: интервалы глубин для выбранных литологических слоев, коды литологии, коды проницаемости пород, значение коэффициентов фильтрации и зон технологического закисления (при наличии). Из третьего листа взяты координаты скважины для ее географической привязки. После формирования единого списка литотипы основных классов объединяются, а для зон технологического закисления выделяется специальный класс. Полный список получившихся литотипов приведен в Таблице 1.

Таблица 1

Список использованных в работе литотипов

Код литотипа	Наименование литотипа
1	гравий, галька
2	песок крупнозернистый
3	песок среднезернистый
4	песок мелкозернистый
5	песчаник
6	алеврит
7	глина
8	зона закисления

Значения каротажей КС и ПС были нормализованы в пределах объединенного набора данных для поддержания согласованности характеристик.

Далее набор данных был разделен на обучающий и тестовый поднаборы, при этом 17 % данных зарезервированы для тестирования. Набор данных для обучения был разделен на обучающий и валидационный поднаборы в соотношении 75 и 25 % от общего набора данных соответственно.

В работе использовались две модели машинного обучения – искусственные нейронные сети (Artificial Neuron Network / ANN) и экстремальный градиентный бустинг (Extreme Gradient Boosting / XGB). Выбор этих моделей основан на их эффективности, показанной в предыдущих работах (I. Goodfellow et al, 2016), (T. Chen, 2016). Данный выбор направлен на использование преимуществ

этих моделей для решения конкретных задач, связанных с выявлением зон технологического закисления. Функции активации, алгоритм обратного распространения и общая архитектура играют ключевую роль в способности ANN выявлять закономерности, делая ее надежным выбором для задачи выявления зон технологического закисления. Способность XGB обрабатывать сложные наборы данных и его устойчивость к переобучению хорошо соответствуют особенностям данных урановой геофизики.

После предварительной обработки данных выполняется процесс обучения и валидации моделей машинного обучения, являющийся ключевым этапом исследования.

Обучение модели ANN включало использование функции RELU в качестве функции активации и оптимизатора ADAM. Процесс обучения происходил в течение 200 эпох,

предоставляя модели значительный опыт работы с данными. Сводка об обучении модели ANN

```
print(ann_model.summary())
```

Model: "sequential"

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 54)	1512
dense_1 (Dense)	(None, 108)	5940
dense_2 (Dense)	(None, 27)	2943
dense_3 (Dense)	(None, 9)	252

 Total params: 10,647
 Trainable params: 10,647
 Non-trainable params: 0

Рис.2. Краткое описание динамики модели ANN

Отчет о классификации модели ANN, раскрывающий ключевые характеристики точности, полноты и F1-меры, и матрицу ошибок ANN, визуально отображающая производительность модели на тестовых данных представлена на рисунках 3 и 4:

```
print(classification_report(Y_trio_test_tehacid.argmax(axis = 1), predictions_ann.argmax(axis = 1)))
```

269/269 [=====] - 0s 1ms/step

	precision	recall	f1-score	support
1	0.48	0.49	0.48	651
2	0.40	0.58	0.47	1363
3	0.51	0.45	0.48	2094
4	0.50	0.48	0.49	1489
5	0.38	0.43	0.41	262
7	0.86	0.71	0.78	1262
8	0.79	0.72	0.75	1467
accuracy			0.56	8588
macro avg	0.56	0.55	0.55	8588
weighted avg	0.58	0.56	0.57	8588

Рис.3. Отчет о классификации модели ANN

В модели XGB использовалось кодирование категориальных данных для совместимости с требованиями модели. Классификатор XGB обучался с параметрами, как показано на рисунке 5, настроенными для баланса между сложностью модели и предсказательной точностью.



Рис.4. Матрица ошибок модели ANN

В модели XGB использовалось кодирование категориальных данных для совместности с требованиями модели. Классификатор XGB обучался с параметрами, как

показано на рисунке 5, настроенными для баланса между сложностью модели и предсказательной точностью.

```

1: model_xgb = xgboost.XGBClassifier(
    learning_rate = 0.01,
    max_depth = 4,
    n_estimators = 500,
    nthread = -1,
    subsample = 0.7,
    scale_pos_weight = 100,
    min_samples_leaf = 300 # 300
)
    
```

Рис.5. Параметры модели XGB

Для количественной оценки производительности вычислен коэффициент точности для модели XGB, обозначенный как `accuracy_score`, предоставляя лаконичную меру правильности предсказаний модели. Вычисленный коэффициент представлен на рисунке 6.

Далее, аналогично модели ANN, модель XGB проанализирована через отчет о классификации XGB и матрицу ошибок XGB, предоставляя детальное разбиение классификационных метрик и поведение модели. Отчет представлен на рисунках 7 и 8.

```
accuracy_xgb = accuracy_score(np.argmax(Y_trio_test_tehacid, axis = 1), y_pred_xgb)
print(accuracy_xgb)

0.6053795994410806
```

Рис.6. Коэффициент XGB Accuracy

```
print(classification_report(np.argmax(Y_trio_test_tehacid, axis=1), y_pred_xgb))
```

	precision	recall	f1-score	support
1	0.52	0.46	0.49	651
2	0.46	0.45	0.45	1363
3	0.50	0.60	0.55	2094
4	0.56	0.54	0.55	1489
5	0.70	0.34	0.45	262
7	0.92	0.70	0.80	1262
8	0.75	0.86	0.80	1467
accuracy			0.61	8588
macro avg	0.63	0.56	0.58	8588
weighted avg	0.62	0.61	0.61	8588

Рис.7. Отчет о классификации модели XGB

Confusion Matrix for XGB Model

1	299.0	214.0	117.0	5.0	15.0	1.0	0.0
2	204.0	609.0	519.0	24.0	3.0	1.0	3.0
3	21.0	387.0	1247.0	359.0	7.0	9.0	64.0
4	1.0	60.0	454.0	811.0	6.0	38.0	119.0
5	40.0	50.0	41.0	18.0	88.0	9.0	16.0
7	6.0	14.0	42.0	87.0	5.0	888.0	220.0
8	0.0	1.0	56.0	135.0	1.0	17.0	1257.0
	1	2	3	4	5	7	8

Рис.8. Матрица ошибок модели XGB

Процесс обучения и валидации является ключевым аспектом методологии работ, позволяя провести оценку предсказательных возможностей и обобщающей

производительности моделей машинного обучения при выявлении зон технологического закисления на урановых месторождениях Казахстана.

Результаты исследования показывают влияние алгоритмов машинного обучения на определение зон технологического закисления на урановых месторождениях в Казахстане. Применение моделей машинного обучения, в частности искусственной нейронной сети (ANN) и модели экстремального градиентного бустинга (XGB), доказало свою эффективность в автоматизации и улучшении идентификации этих важных зон при обработке месторождений урана методом подземного скважинного выщелачивания. Комплексное

тестирование построенных моделей на всем наборе данных продемонстрировало многообещающие результаты. Особого внимания заслуживает интерпретационная способность моделей различать зоны технологического закисления в наборе данных. Результаты сравнения точности по каждой скважине в наборе данных, подробно описанные в таблице 2 и приведенные на рисунке 9, дают четкое представление об эффективности алгоритмов машинного обучения в контексте геофизики урана.

Таблица 2

Сравнение точности предсказания моделей ANN и XGB

№	Скважина	ANN accuracy	XGB accuracy
1	83-3-7	0,51	0,61
2	85-1-1	0,52	0,68
3	85-1-4	0,49	0,56
4	85-2-1	0,63	0,66
5	85-2-2	0,35	0,62
6	85-2-3	0,37	0,74
7	85-2-4	0,28	0,53
8	86СВ-3-1	0,58	0,53
9	86СВ-3-6	0,62	0,60
10	86СВ-4-1	0,53	0,48
11	86СВ-4-2	0,53	0,66
12	86св-3-5	0,56	0,55
13	86св-3-7	0,38	0,42
14	86св-3-9-1	0,36	0,50
15	86св-4-3	0,62	0,61
16	86св-4-4	0,15	0,15
17	86св-5-1	0,50	0,65
18	86св-5-11-1	0,63	0,61
19	86св-5-2	0,42	0,52
20	86св-5-3	0,63	0,67
21	86св-5-5	0,58	0,66
22	86св-5-6	0,66	0,67
23	86св-5-7	0,54	0,63
24	86св-5-8	0,53	0,59
25	86св-5-9	0,20	0,22
26	86св-6-1	0,45	0,42
27	86св-6-2	0,43	0,40
28	86св-6-3	0,59	0,55
29	86св-7-1	0,45	0,48
30	86св-7-2	0,41	0,43
31	86св-7-3	0,41	0,52
32	87св-1-12-1	0,42	0,55
33	87св-2-1	0,49	0,50
34	87св-2-2	0,53	0,63

№	Скважина	ANN accuracy	XGB accuracy
35	87св-2-3	0,59	0,71
36	87св-2-4	0,77	0,79
37	87св-2-5	0,64	0,73
38	87св-2-6	0,39	0,61
39	87св-2-7	0,62	0,72
40	87св-3-5	0,52	0,73
41	87св-3-6	0,78	0,73
42	87св-3-8	0,57	0,64
43	87св-3-9	0,69	0,68
44	89св-1-1в	0,81	0,85
45	89св-1-3в	0,53	0,63
46	89св-1-6в	0,66	0,71
47	89св-1-8в	0,63	0,79
48	89св-146нр	0,63	0,70
49	89св-2-1в	0,68	0,73
50	89св-3-5	0,53	0,72
51	89св-3-7	0,75	0,69
52	89св-3-8	0,73	0,70
53	89св-4-2в	0,73	0,88
54	89св-4-3в	0,63	0,68
55	89св-6-3	0,35	0,52
56	89св-6-4-1	0,65	0,70
57	89св-7-1	0,70	0,73
58	89св-7-11	0,63	0,77
59	89св-7-2-2	0,74	0,77
60	89св-7-3	0,78	0,77
61	89св-7-6	0,47	0,62
62	89св-7-7-2	0,49	0,59
63	89св-7-8	0,56	0,80
64	89св-7-9	0,72	0,77
65	89св-8-1	0,66	0,74
66	89св-8-2	0,68	0,76
67	95-2-1	0,67	0,78
68	95-2-2	0,70	0,86

Сравнение точности предсказания рассматриваемых моделей представлено на рисунке 9.

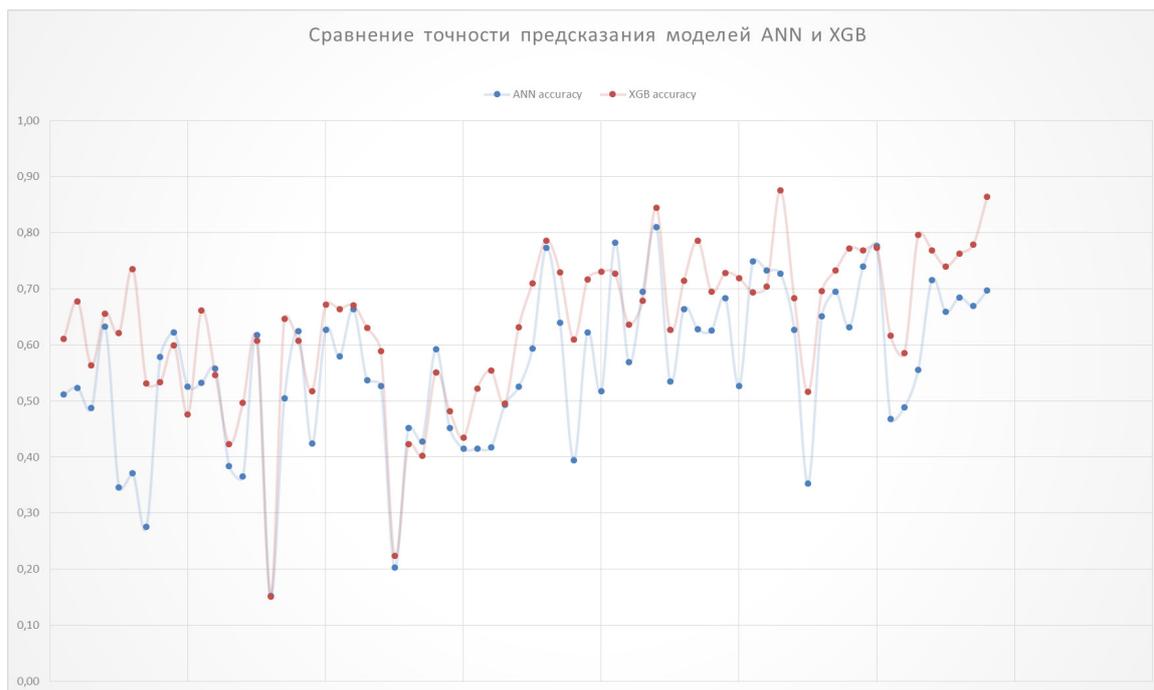


Рис.9. Сравнение точности предсказания моделей ANN и XGB

В таблице 3 и на рисунке 10 приведены данные для метрики F1-score для скважин, в которых имелись зоны технологического закисления.

Таблица 3

Сравнение F1-score для скважин с технологическим закислением

	Скважина	ANN F1-score	XGB F1-score
1	85-1-1	0,50	0,68
2	85-2-1	0,61	0,65
3	85-2-2	0,32	0,64
4	85-2-3	0,47	0,73
5	85-2-4	0,25	0,54
6	86св-3-5	0,62	0,56
7	87св-1-12-1	0,36	0,52
8	87св-2-1	0,37	0,50
9	87св-2-2	0,65	0,59
10	87св-2-3	0,72	0,70
11	87св-2-4	0,56	0,80
12	87св-2-5	0,65	0,72
13	87св-2-6	0,54	0,58
14	87св-2-7	0,59	0,71
15	87св-3-5	0,68	0,73
16	87св-3-6	0,66	0,72
17	87св-3-8	0,74	0,60
18	87св-3-9	0,47	0,66
19	89св-1-1в	0,86	0,84
20	89св-1-3в	0,58	0,67
21	89св-1-6в	0,72	0,71

	Скважина	ANN F1-score	XGB F1-score
22	89св-1-8в	0,70	0,78
23	89св-146пр	0,60	0,70
24	89св-2-1в	0,67	0,74
25	89св-3-5	0,61	0,74
26	89св-3-7	0,69	0,70
27	89св-3-8	0,65	0,73
28	89св-4-2в	0,74	0,87
29	89св-4-3в	0,64	0,69
30	89св-6-3	0,42	0,58
31	89св-6-4-1	0,63	0,70
32	89св-7-1	0,72	0,75
33	89св-7-11	0,61	0,77
34	89св-7-2-2	0,74	0,77
35	89св-7-3	0,75	0,78
36	89св-7-6	0,56	0,66
37	89св-7-7-2	0,51	0,63
38	89св-7-8	0,58	0,82
39	89св-7-9	0,71	0,78
40	89св-8-1	0,64	0,74
41	89св-8-2	0,62	0,77
42	95-2-1	0,66	0,77
43	95-2-2	0,64	0,86

Сравнение F1-score для скважин, где присутствуют зоны технологического закисления показано на рисунке 10.

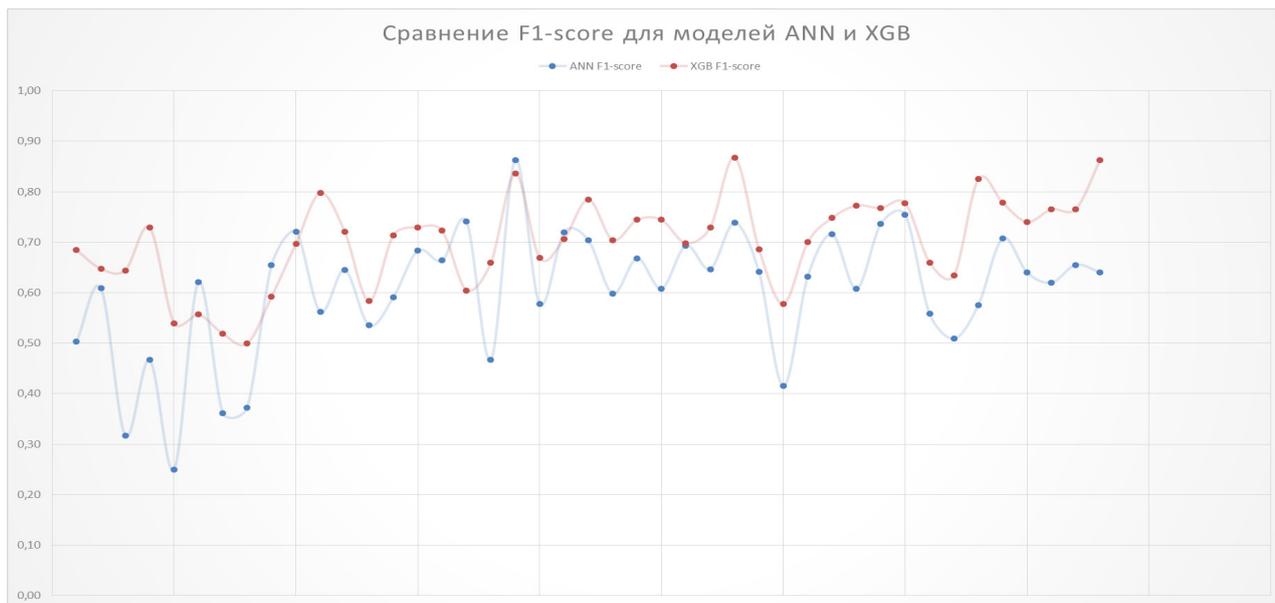


Рис.10. Сравнение F1-score для скважин, где присутствуют зоны технологического закисления

Эффективность работы моделей оценивалась в контексте интерпретации зон технологического закисления по всему набору данных. Это включало применение моделей ко всем 68 скважинам. Модели успешно продемонстрировали свою способность выделять и классифицировать зоны технологического закисления, предоставляя ценные исследовательские данные для геологических исследований в контексте урановой геофизики.

Модели машинного обучения, такие как использованные в этом исследовании модели ANN и XGB, демонстрируют способность автоматизировать и ускорить процесс идентификации зон технологического закисления. Используя передовые алгоритмы распознавания шаблонов, эти модели эффективно анализируют сложные геологические наборы данных, обеспечивая быструю и точную идентификацию зон технологического закисления.

Ручной характер традиционных методов приводит к продолжительному времени обработки каждой скважины. Алгоритмы машинного обучения работают на порядок быстрее, повышая общую эффективность процесса интерпретации. Ускорение времени обработки особенно важно в масштабных геофизических исследованиях, где требуется систематический анализ множества скважин.

Более того, субъективность, присутствующая ручному анализу, уменьшается благодаря объективной и последовательной природе моделей машинного обучения. Алгоритмы обучаются на обширных наборах данных, изучая тонкие закономерности, которые могут ускользнуть от ручного анализа. Это улучшает точность и надежность идентификации зон технологического закисления, способствуя более надежным геологическим оценкам.

ЗАКЛЮЧЕНИЕ

Исследование применения методов машинного обучения (МО / ML) в геофизике урановых месторождений, особенно при выявлении зон технологического закисления, привело к многообещающим результатам. Комплексный сбор данных из 68 скважин обеспечил прочную основу для ML-моделей, включая данные по каротажам, литологии и геопривязке. Тщательные этапы предварительной обработки данных, включая разделение скважин с и без зон технологического закисления, и нормализацию ключевых параметров каротажей, гарантировали качество и актуальность набора данных.

Выбранные ML-модели, искусственные нейронные сети (ANN) и экстремальный градиентный бустинг (XGB), продемонстрировали свою эффективность в обработке

сложных геологических данных, связанных с урановыми месторождениями. Процессы обучения и валидации, с подробными исследованиями гиперпараметров и метрик производительности, показали возможности этих моделей точно идентифицировать зоны технологического закисления.

Представление результатов показало, что МО отлично справляется с интерпретацией зон технологического закисления на всем наборе данных. Сравнение с традиционными методами подчеркнуло значительные преимущества в экономии времени и автоматизации, предлагаемых МО, преодолевая проблемы ручной идентификации. Интерпретация результатов подчеркнула успех ML-моделей в обеспечении более эффективного и автоматизированного подхода к выявлению зон технологического закисления. Оценка устойчивости и обобщаемости подтвердила стабильную производительность моделей в разнообразных геологических условиях, подчеркивая их практическую ценность.

Работа выполнена при финансовой поддержке Комитета науки Министерства науки и высшего образования Республики Казахстан Республики Казахстан: грант № AP14869110 «Повышение точности решения задач интерпретации данных геофизических исследований скважин на урановых месторождениях с использованием методов машинного обучения» (2022 -2024гг.).

СПИСОК ЛИТЕРАТУРЫ

1. Петров Н.Н., Язиков В.Г., Аубакиров Х.Б., Плеханов В.Н., Верщков А.Ф., Лухтин В.Ф. Урановые месторождения Казахстана (экзогенные). Алматы: Гылым, 1995 – 264 с.
2. Петров Н.Н., Язиков В.Г., Аубакиров Х.Б., Плеханов В.Н., Верщков А.Ф., Лухтин В.Ф. Урановые месторождения: Новая эра, №1, 2014 г.
3. Перельман А. И., Гидрогенные месторождения урана. Основы теории образования, М.: Атомиздат, 1980. 270 с.
4. Евсеева Л. С., Перельман А. И. Геохимия урана в зоне гипергенеза. М.: Госатомиздат, 1962. 239 с.
5. Перельман А. И., Экзогенные эпигенетические месторождения урана. Условия образования, . М.: Атомиздат, 1965. 323 с.
6. K. Helbig and S. Treitel, “Computational Neural Networks for Geophysical Data Processing,” Handbook of Geophysical Exploration, Seismic Exploration, vol. 30, 2001.
7. M. Van der Baan and C. Jutten, “Neural networks in geophysical applications,” Geophysics, 65 (4), pp. 1032-1047, 2000.
8. L. Hai An, “Neutral Network in Lithology Determination,” Tap chi Tin hoc va Dieu khien hoc, T.16, S.2, pp 59-62, 2000.

9. М.А. Сенилов, “Развитие интеллектуальных методов обработки геофизических данных,” Искусственный интеллект, 4, pp 357 - 364, 2003.

10. S. Maiti, R. K. Tiwari, and H.-J. Kumpel, “Neural network modelling and classification of lithofacies using well log data: a case study from KTB borehole site,” Geophys. J. Int., vol. 169, pp 733–746, 2007.

11. D. Benaouda et al., “Inferring the lithology of borehole rocks by applying neural network classifiers to downhole logs: an example from the Ocean Drilling Program,” Geophys. J. Int., vol. 136, pp 477 - 491, 1999.

12. V. Tschannen et al., “Facies classification from well logs using an inception convolutional network,” Computer Vision and Pattern Recognition (cs.CV), arXiv:1706.00613, 2017.

13. S. Chikhi, M. Batouche, and H. Shout, “Hybrid Neural Network Methods for Lithology Identification in the Algerian Sahara,” International Journal of Geological and Environmental Engineering, vol. 1, no. 4, 2007.

14. I. Bachri, M. Hakdaoui, M. Raji, AC. Teodoro, A. Benbouziane, “Machine Learning Algorithms for Automatic Lithological Mapping Using Remote Sensing Data: A Case Study from Souk Arbaa Sahel”, Sidi Ifni Inlier, Western Anti-Atlas, Morocco. ISPRS International Journal of Geo-Information 8(6):248, 2019.

15. Р. И. Мухамедиев, Я. И. Кучин, “Средства автоматизации обработки данных геофизического исследования скважин на месторождениях урана пластово-инфильтрационного типа”, Электронный журнал Cloud of Science Т. 2. № 3, 2015.

16. Амиргалиев Е. Н. и др. Методы машинного обучения в задачах распознавания пород на урановых месторождениях //Известия НАН РК. – 2013. – №. 3. – С. 82-88.

17. Kuchin Y. I., Grundspenkis J. Machine Learning Methods for Identifying Composition of Uranium Deposits in Kazakhstan //Appl. Comput. Syst. – 2017. – Т. 22. – №. 1. – С. 21-27.

18. Mukhamediev R. I. et al. Determination of Reservoir Oxidation Zone Formation in Uranium Wells Using Ensemble Machine Learning Methods //Mathematics. – 2023. – Т. 11. – №. 22. – С. 4687. <https://doi.org/10.3390/math11224687>.

19. Kuchin, Y.; Mukhamediev, R.; Yunicheva, N.; Symagulov, A.; Abramov, K.; Mukhamedieva, E.; Zaitseva, E.; Levashenko, V. Application of Machine Learning Methods to Assess Filtration Properties of Host Rocks of Uranium Deposits in Kazakhstan. Appl. Sci. 2023, 13, 10958. <https://doi.org/10.3390/app131910958>.

20. Haykin, S.S. Neural Networks: A Comprehensive Foundation, <https://books.google.ru/books?id=PSAPAQAAMAAJ>, 1994.

21. Ian Goodfellow and Yoshua Bengio and Aaron Courville, Deep Learning, <http://www.deeplearningbook.org>, MIT Press, 2016.

22. Tianqi Chen; Carlos Guestrin, XGBoost: A Scalable Tree Boosting System, doi:10.1145/2939672.2939785[DOI], <http://arxiv.org/abs/1603.02754>, 2016

REFERENCES

1. Petrov N.N., YAzikov V.G., Aubakirov H.B., Plekhanov V.N., Vershchikov A.F., Luhtin V.F. Uranovye mestorozhdeniya Kazahstana (ekzogennye). Almaty: Gylym, 1995 – 264 p.
2. Petrov N.N., YAzikov V.G., Aubakirov H.B., Plekhanov V.N., Vershchikov A.F., Luhtin V.F. Uranovye mestorozhdeniya: Novaya era, №1, 2014.
3. Perel'man A. I., Gidrogennye mestorozhdeniya urana. Osnovy teorii obrazovaniya, M.: Atomizdat, 1980. 270 p.

4. Evseeva L., Perel'man A. I. Geohimiya urana v zone gipergeneza. M.: Gosatomizdat, 1962. 239 p.
5. Perel'man A. I., Ekzogennye epigeneticheskie mestorozhdeniya urana. Usloviya obrazovaniya, . M.: Atomizdat, 1965. 323 p.
6. K. Helbig and S. Treitel, "Computational Neural Networks for Geophysical Data Processing," Handbook of Geophysical Exploration, Seismic Exploration, vol. 30, 2001.
7. M. Van der Baan and C. Jutten, "Neural networks in geophysical applications," Geophysics, 65 (4), pp. 1032-1047, 2000.
8. L. Hai An, "Neutral Network in Lithology Determination," Tap chi Tin hoc va Dieu khien hoc, T.16, S.2, pp 59-62, 2000.
9. M.A. Senilov, "Razvitie intellektual'nyh metodov obrabotki geofizicheskikh dannyh," Iskustvennyj intellekt, 4, pp 357 - 364, 2003.
10. S. Maiti, R. K. Tiwari, and H.-J. Kumpel, "Neural network modelling and classification of lithofacies using well log data: a case study from KTB borehole site," Geophys. J. Int., vol. 169, pp 733-746, 2007.
11. D. Benaouda et al., "Inferring the lithology of borehole rocks by applying neural network classifiers to downhole logs: an example from the Ocean Drilling Program," Geophys. J. Int., vol. 136, pp 477 - 491, 1999.
12. V. Tschannen et al., "Facies classification from well logs using an inception convolutional network," Computer Vision and Pattern Recognition (cs.CV), arXiv:1706.00613, 2017.
13. S. Chikhi, M. Batouche, and H. Shout, "Hybrid Neural Network Methods for Lithology Identification in the Algerian Sahara," International Journal of Geological and Environmental Engineering, vol. 1, no. 4, 2007.
14. I. Bachri, M. Hakdaoui, M. Raji, AC. Teodoro, A. Benbouziane, "Machine Learning Algorithms for Automatic Lithological Mapping Using Remote Sensing Data: A Case Study from Souk Arbaa Sahel", Sidi Ifni Inlier, Western Anti-Atlas, Morocco. ISPRS International Journal of Geo-Information 8(6):248, 2019.
15. R. I. Muhamediev, YA. I. Kuchin, "Sredstva avtomatizatsii obrabotki dannyh geofizicheskogo issledovaniya skvazhin na mestorozhdeniyah urana plastovo-infil'tracionnogo tipa", Elektronnyj zhurnal Cloud of Science T. 2. № 3, 2015.
16. Amirgaliev E. N. i dr. Metody mashinnogo obucheniya v zadachah raspoznavaniya porod na uranovyh mestorozhdeniyah //Izvestiya NAN RK. – 2013. – №. 3. – P. 82-88.
17. Kuchin Y. I., Grundspenkis J. Machine Learning Methods for Identifying Composition of Uranium Deposits in Kazakhstan //Appl. Comput. Syst. – 2017. – T. 22. – №. 1. – P. 21-27.
18. Mukhamediev R. I. et al. Determination of Reservoir Oxidation Zone Formation in Uranium Wells Using Ensemble Machine Learning Methods //Mathematics. – 2023. – T. 11. – №. 22. – S. 4687. <https://doi.org/10.3390/math11224687>.
19. Kuchin, Y.; Mukhamediev, R.; Yunicheva, N.; Symagulov, A.; Abramov, K.; Mukhamedieva, E.; Zaitseva, E.; Levashenko, V. Application of Machine Learning Methods to Assess Filtration Properties of Host Rocks of Uranium Deposits in Kazakhstan. Appl. Sci. 2023, 13, 10958. <https://doi.org/10.3390/app131910958>.
20. Haykin, S.S. Neural Networks: A Comprehensive Foundation, <https://books.google.ru/books?id=PSAPAQAAMAAJ>, 1994.
21. Ian Goodfellow and Yoshua Bengio and Aaron Courville, Deep Learning, <http://www.deeplearningbook.org>, MIT Press, 2016.
22. Tianqi Chen; Carlos Guestrin, XGBoost: A Scalable Tree Boosting System, doi:10.1145/2939672.2939785[DOI], <http://arxiv.org/abs/1603.02754>, 2016.

МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНА ОТЫРЫП, ҚАЗАҚСТАННЫҢ УРАН КЕН ОРЫНДАРЫНДА ТЕХНОЛОГИЯЛЫҚ ҚЫШҚЫЛДАНУ АЙМАҚТАРЫН

К. Абрамов¹, Н.Р. Юничева^{1,2*} т. э. к., доцент, Я. И. Кучин^{1,3}, Е. Мухамедиева¹

¹Ақпараттық және есептеуіш технологиялар институты, Алматы, 050010,

²Алматы энергетика және байланыс университеті, Алматы, 050013

³Сатбаев университеті, Алматы, 050013

E-mail: ykuchin@mail.ru, naduni@mail.ru

Сілтілеу кезінде уран кен орындарындағы технологиялық қышқылдану аймақтарын анықтау уран алу процесін дәл бақылау және оңтайландыру үшін қажет. Технологиялық қышқылдану аймағын дұрыс анықтамау қышқыл реагенттерін шамадан тыс пайдалануға әкелуі мүмкін, бұл шығындарды арттырып қана қоймайды, сонымен қатар жағымсыз экологиялық зардаптарды тудыруы мүмкін. Жұмыста Қазақстандағы уран кен орындарындағы технологиялық қышқылдану аймақтарын қолмен анықтауға байланысты мәселелерді шешуге көзқарас ұсынылды. Бұл тәсіл осы маңызды аймақтарды анықтауды автоматтандыру үшін машиналық оқыту алгоритмдерін зерттеуді қамтиды. Жасанды нейрондық желі (ANN) және экстремалды градиентті күшейту (XGB) модельдерін қолдану уран кен орындарын жерасты ұңғымаларын шаймалау әдісімен өңдеу кезінде осы маңызды аймақтарды автоматтандыруда және сәйкестендіруді жақсартуда тиімділігін көрсетті. Сонымен, ANN моделі үшін F1-score метрикасы бойынша қышқылдану аралықтарын оқшаулау дәлдігі 0,75, ал XGB моделі үшін 0,80 құрайды.

Түйін сөздер: машиналық оқыту, уран өндіру, технологиялық қышқылдану аймағы, жерасты ұңғымаларын шаймалау, жасанды нейрондық желілер (Artificial Neuron Network / ANN), экстремалды градиентті күшейту (Extreme Gradient Boosting / XGB).

DETERMINATION OF TECHNOLOGICAL OXIDATION ZONES AT URANIUM DEPOSITS IN KAZAKHSTAN USING MACHINE LEARNING METHODS MACHINE LEARNING

К. Abramov¹, N. Yunicheva^{1,2*} *Candidate of Technical Sciences, associate professor*, **Y. Kuchin^{1,3}, E. Mukhamedieva¹**

¹*Institute of Information and Computational Technologies MSHE RK, 050010, Almaty*

²*Almaty University of Power Engineering and Telecommunications (AUPET), 050013, Almaty*

³*Satbayev University (KazNRTU), 050013, Almaty*

E-mail: ykuchin@mail.ru, naduni@mail.ru

The determination of technological acidification zones in uranium deposits during leaching is necessary for precise control and optimization of the uranium extraction process. Incorrect determination of the technological acidification zone can lead to excessive use of acidic reagents, which not only increases costs, but also can cause undesirable environmental consequences. The paper proposes an approach to solving issues related to the manual determination of zones of technological acidification in uranium deposits in Kazakhstan. The approach includes the study of machine learning algorithms to automate the identification of these critical areas. The use of artificial neural network (ANN) models and the extreme gradient boosting (XGB) model has shown its effectiveness in automating and improving the identification of these important zones during the mining of uranium deposits by underground borehole leaching. Thus, the accuracy of acidification intervals according to the F1-score metric for the ANN model is 0,75, and for the XGB model it is 0,80.

Keywords: machine learning, uranium mining, technological oxidation zone, underground borehole leaching, artificial neural networks (Artificial Neuron Network / ANN), Extreme Gradient Boosting (XGB).

Сведения об авторах/Авторлар туралы мәліметтер/Information about authors:

Абрамов Кирилл - магистр компьютерных систем, инженер ИИВТ КН МНВО РК, *abramc@mail.ru*, ORCID: <https://orcid.org/0000-0002-0646-3714>

Кучин Ян Игоревич — PhD студент, старший научный сотрудник ИИВТ КН МНВО РК, *ykuchin@mail.ru*, ORCID ID: <https://orcid.org/0000-0002-5271-9071>

Юничева Надия Рафкатовна — к.т.н., доцент, ведущий научный сотрудник ИИВТ КН МНВО РК; *naduni@mail.ru*. ORCID ID: <https://orcid.org/0000-0001-6351-3450>

Мухамедиева Елена — научный сотрудник ИИВТ МНВО РК, *muhamedijeva@gmail.com*. ORCID ID: <https://orcid.org/0000-0001-9596-4432>

Абрамов Кирилл – компьютерлік жүйелер магистрі, ҚР БҒМ ҒК АЕТИ инженері, *abramc@mail.ru*, ORCID: <https://orcid.org/0000-0002-0646-3714>

Кучин Ян Игоревич - PhD студенті, ҚР БҒМ ҒК АЕТИ аға ғылыми қызметкері; *ykuchin@mail.ru*, ORCID идентификаторы: <https://orcid.org/0000-0002-5271-9071>

Юничева Надия Рафкатовна - т. ғ. к., доцент, ҚР БҒМ ҒК АЕТИ жетекші ғылыми қызметкері; *naduni@mail.ru*, ORCID идентификаторы: <https://orcid.org/0000-0001-6351-3450>

Мұхамедиев Равиль Ильгизович - инженерия ғылымдарының докторы, ҚазҰТУ профессоры, *ravil.muhamedyev@gmail.com*, <https://orcid.org/0000-0002-3727-043X>

Мұхамедиева Елена - ҚР БҒМ ҒК АЕТИ ғылыми қызметкері, *muhamedijeva@gmail.com*, ORCID идентификаторы: <https://orcid.org/0000-0001-9596-4432>

Abramov Kirill. - master of computer systems, engineer of the Institute of Information and Computational Technologies, *abramc@mail.ru*, ORCID: <https://orcid.org/0000-0002-0646-3714>

Kuchin Yan - PhD student, senior researcher of the Institute of Information and Computational Technologies; *ykuchin@mail.ru*; ORCID ID: <https://orcid.org/0000-0002-5271-9071>

Yunicheva Nadiya - Candidate of Technical Sciences, *associate professor* of the Institute of High Technologies; *naduni@mail.ru*; ORCID ID: <https://orcid.org/0000-0001-6351-3450>

Mukhamedieva Elena is a researcher at the Institute of Information and Computational Technologies of the Ministry of Education and Science of the Republic of Kazakhstan, *muhamedijeva@gmail.com*, ORCID ID: <https://orcid.org/0000-0001-9596-4432>

Вклад авторов/Авторлардың қосқан үлесі/Authors' contribution

Абрамов Кирилл - создание программного обеспечения, проведение статистического анализа

Кучин Ян Игоревич — разработка методологии, проведение статистического анализа, ресурсы

Юничева Надия Рафкатовна — проведение исследования, подготовка и редактирование текста, визуализация

Мухамедиева Елена — разработка концепции, подготовка и редактирование текста, визуализация

Абрамов Кирилл – бағдарламалық жасақтама жасау, статистикалық талдау жүргізу

Кучин Ян Игоревич - әдістемені әзірлеу, статистикалық талдау жүргізу, ресурстар

Юничева Надия Рафкатовна - зерттеу жүргізу, мәтінді дайындау және өңдеу, көрнекілік

Мухамедиева Елена - тұжырымдаманы әзірлеу, мәтінді дайындау және өңдеу, көрнекілік

Abramov Kirill. - creating software, conducting statistical analysis

Kuchin Yan - methodology development, conducting statistical analysis, resources

Yunicheva Nadiya - conducting a research, preparing and editing the text, visualization

Mukhamedieva Elena - concept development, preparing and editing the text, visualization