

УДК 622.24

## Применение методов машинного обучения для повышения качества крепления скважин

Д. В. Шаляпин<sup>1, 2</sup>, Д. Л. Бакиров<sup>2</sup>, М. М. Фаттахов<sup>2</sup>, А. Д. Шаляпина<sup>1\*</sup>,  
А. В. Мелехов<sup>2</sup>, А. В. Щербаков<sup>2</sup>, В. Г. Кузнецов<sup>1</sup>

<sup>1</sup>Тюменский индустриальный университет, г. Тюмень, Россия

<sup>2</sup>Филиал ООО «ЛУКОЙЛ-Инжиниринг» «КогалымНИПИнефть», г. Тюмень, Россия

\*e-mail: shaljapinaad@tyuiu.ru

*Аннотация.* В статье рассматриваются проблемы, связанные с повышением качества крепления скважин на Пяяхинском месторождении, в частности большой объем работы по нахождению взаимосвязи между лабораторными исследованиями и фактическими данными с промысла; трудность нахождения логически обусловленных связей между параметрами и итоговым качеством крепления скважин. Описан новый подход к оценке влияния различных параметров, основанный на математическом аппарате, который исключает субъективные экспертные оценки, что в дальнейшем позволит применить данный метод на месторождениях с различными горно-геологическими условиями. Авторы предлагают использовать принципы математической обработки больших массивов данных с использованием нейронных сетей, обученных прогнозированию характеристик качества крепления скважины (сплошность контакта цементного камня с породой и с обсадной трубой). С учетом предварительно выявленных факторов выработаны решения по повышению герметичности крепи скважин и адгезии цементного камня с ограничивающими поверхностями.

*Ключевые слова:* машинное обучение; математические методы; адгезия; крепь скважины; Пяяхинское месторождение

## The applying of machine learning methods to improve the quality of well casing

Denis V. Shalyapin<sup>1, 2</sup>, Daniyar L. Bakirov<sup>2</sup>, Marsel M. Fattakhov<sup>2</sup>,  
Adelya D. Shalyapina<sup>1\*</sup>, Alexander V. Melekhov<sup>2</sup>, Andrey V. Sherbakov<sup>2</sup>,  
Vladimir G. Kuznetsov<sup>1</sup>

<sup>1</sup>Industrial University of Tyumen, Tyumen, Russia

<sup>2</sup>KogalymNIPIneft Branch of LUKOIL-Engineering LLC, Tyumen, Russia

\*e-mail: shaljapinaad@tyuiu.ru

*Abstract.* The article is devoted to the quality of well casing at the Pyakyakhinskoye oil and gas condensate field. The issue of improving the quality of well casing is associated with many problems, for example, a large amount of work on finding the relationship between laboratory studies and actual data from the field; the difficulty of finding logically determined relationships between the parameters and the final quality of well casing. The text gives valuable information on a new approach to assessing the impact of various parameters, based on a mathematical apparatus that excludes subjective expert assessments, which in the future will allow applying this method to deposits with different rock and geological con-

ditions. We propose using the principles of mathematical processing of large data sets applying neural networks trained to predict the characteristics of the quality of well casing (continuity of contact of cement with the rock and with the casing). Taking into account the previously identified factors, we developed solutions to improve the tightness of the well casing and the adhesion of cement to the limiting surfaces.

*Key words:* machine learning; mathematics methods; adhesion; well casing; the Pyakyakhinskoye oil and gas condensate field

## **Введение**

Современное состояние нефтегазовой отрасли России и мира характеризуется тем, что многие крупные месторождения углеводородов находятся на завершающей стадии разработки, а новые месторождения располагаются в труднодоступных регионах (Арктика, Заполярье), что делает добычу полезных ископаемых на данных территориях зачастую нерентабельной и предопределяет необходимость использования нетривиальных решений по оптимизации затрат и технологических процессов [1–4], в том числе по автоматизированной обработке больших массивов данных.

Промышленное разбуривание Пяяхинского нефтегазоконденсатного месторождения показывает, что задача повышения качества крепления скважин является актуальной, несмотря на реализуемый в течение многих лет комплекс мер по ее улучшению [5–8] — сплошность контакта цементного камня с обсадной трубой и герметичность крепи скважины находятся на уровне 20–30 % по данным акустической цементометрии (АКЦ) и спектральной гамма-дефектометрии-толщинометрии (СГДТ).

Накопленный массив данных по Пяяхинскому месторождению позволяет предопределять возможность использования математического моделирования для комплексного решения вопроса повышения качества крепления скважин, а также обеспечивать прогнозирование качества крепления в зависимости от факторов, которые явно или неявно (косвенно) могут повлиять на герметичность крепи.

## **Теоретическое обоснование применения методов и входные параметры**

Машинное обучение (Machine Learning) — это комплекс алгоритмов, подготовленных для предсказания какого-либо события [9]. Принципиальная схема работы математического аппарата следующая: создается база данных, включающая свершившиеся события и их параметры; алгоритм специально «нацеливают» на прогнозирование какой-либо величины или какого-либо события (путем ввода новых данных, объединения нескольких переменных в одну, исключения маловажных величин из модели и т. д.); затем в модель отдельно вносятся актуальные данные, которых не было до этого, без значения искомой величины; после чего алгоритм на основе базы данных делает прогноз, используя входные параметры.

Необходимо отметить, что существует большое множество методов машинного обучения, каждый из которых эффективен в своей области [10]:

1. Регрессия. Применяется при прогнозировании числовых значений.
2. Классификация. Применяется при прогнозировании событий на основе связанных с ним переменных.

3. Кластеризация. Разделение большого количества событий на группы (кластеры), каждая группа характеризуется определенными величинами переменных.

4. Уменьшение размерности. Группирование различных параметров по признакам.

5. Поиск аномалий. Нахождение редких событий или объектов, которые значительно отличаются от остального массива данных.

На первоначальном этапе была сформирована база данных по 73 скважинам, включающая 64 оцениваемых параметра:

1. Данные инклинометрии (длины вертикального участка, участка стабилизации, транспортного ствола; величина зенитного угла на участке стабилизации, угла входа в пласт; интенсивность изменения пространственного угла на первом участке набора, на втором участке донабора).

2. Эксцентричное положение обсадной колонны (ОК) (на вертикальном участке, на первом и на втором участках набора пространственного угла, на участке стабилизации; количество центраторов по длине всей колонны).

3. Реологические показатели бурового раствора перед цементированием (плотность, условная вязкость, фильтрация, рН, толщина корки).

4. Состав и технологические параметры используемых тампонажных растворов (водотвердое отношение; концентрации понизителя фильтрации, пластификатора, замедлителя сроков схватывания; пеногасители, плотность, водоотделение, время загустевания, прочность).

5. Технологические параметры процесса цементирования (рабочее давление, давление при посадке пробки, время промывки перед спуском ОК, расход при спуске ОК, давление промывки, количество остановок для промывки), а также результаты качества крепления скважины по результатам АКЦ и СГДТ (состояние контакта с колонной, с горной породой, оценка герметичности).

Одновременно с этим осуществлялся подбор программного обеспечения для проведения вычислений. Основная цель заключалась в том, чтобы подобрать такую программу, использование которой не требовало бы узкоспециализированных знаний языков программирования — была выбрана аналитическая система Orange, позволяющая проводить вычисления с помощью графических виджетов с уже готовыми открытыми алгоритмами на языке программирования Python [11]. Для выполнения математических действий программа использует только внутренние мощности персонального компьютера, в отличие от других подобных продуктов (например, MS Azure Machine Learning), которые выполняют вычисления на удаленных серверах.

### **Особенности применяемых алгоритмов**

Расчеты проводились с использованием шести алгоритмов, сильными сторонами которых является решение задач кластеризации.

1. Метод логической регрессии. Переработанный математический аппарат линейной регрессии для решения задач по бинарной классификации. Например, для логической регрессии также требуется нахождение весовых коэффициентов, а разница заключается в использовании логической функции (сигмоиды) для преобразования выходного сигнала (рис. 1). Выходное число через функцию активации изменяется в пределах от 0 до 1, данная особенность полезна, когда необходимо оценить вероятность наступления одного из двух событий.




Рис. 1. Логическая функция — сигмоида

2. Дерево решений. Представляет собой двоичное дерево, каждый узел которого является входной переменной и точкой разделения для этой переменной. «Листовые» узлы — это выходные переменные, которые используются в качестве прогнозной величины (рис. 2).

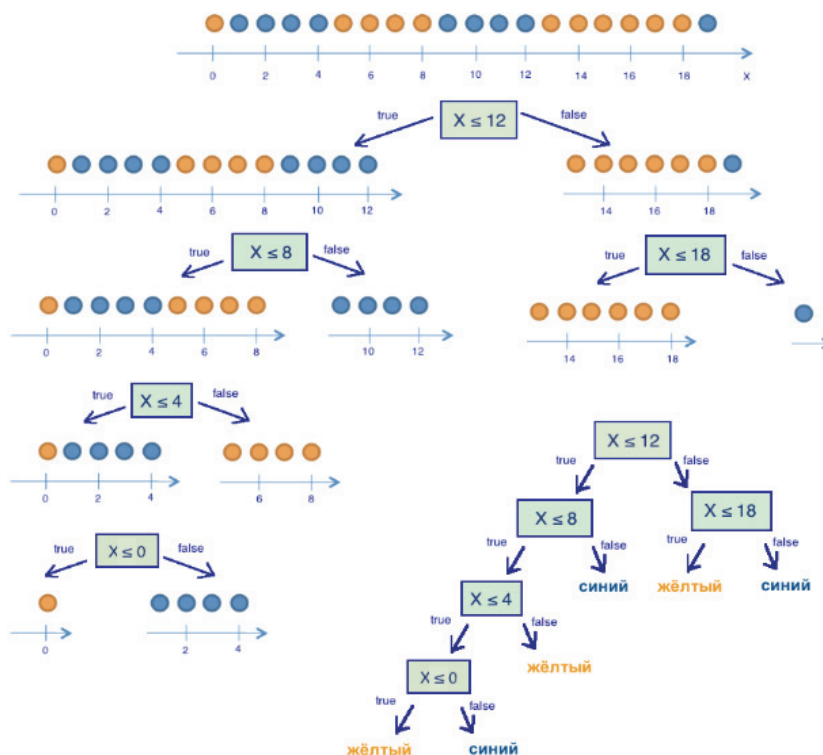


Рис. 2. Визуализация дерева решений

3. Байесовский классификатор. Модель включает в себя два типа вероятностей:

- вероятность каждого класса;
- условная вероятность для каждого класса при каком-либо значении  $X$ .

Для применения данного алгоритма необходима «тренировка» на тестовой базе данных для достижения высоких прогнозных показателей.

После чего данный классификатор может давать адекватные предиктивные результаты. Особенность метода заключается в том, что все входные параметры считаются независимыми (рис. 3).

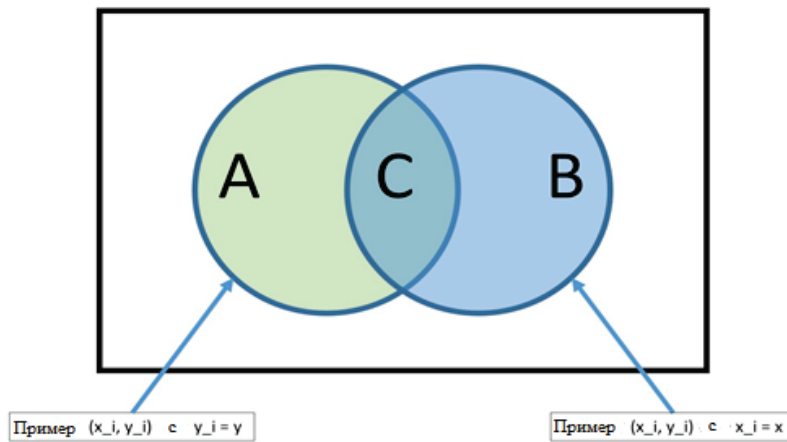


Рис. 3. Принципиальная схема Байесовского классификатора

4. Лес случайных решений. Для работы данного метода требуется кластеризация исходной базы данных, чтобы создать для каждой из выборок предиктивную модель, после чего полученные результаты усредняются, чтобы получить наиболее точную оценку, а также определить параметры с высокой степенью влияния на результат (рис. 4).




Рис. 4. Принципиальная схема леса случайных решений

5. Нейронная сеть.

Искусственная нейронная сеть является математическим подобием человеческого мозга в части принципа обработки информации (рис. 5). Человеческий нейрон, помимо сбора, обработки и передачи информации к другим нейронам, выполняет еще ряд сложнейших функций по поддержанию жизнедеятельности человека.

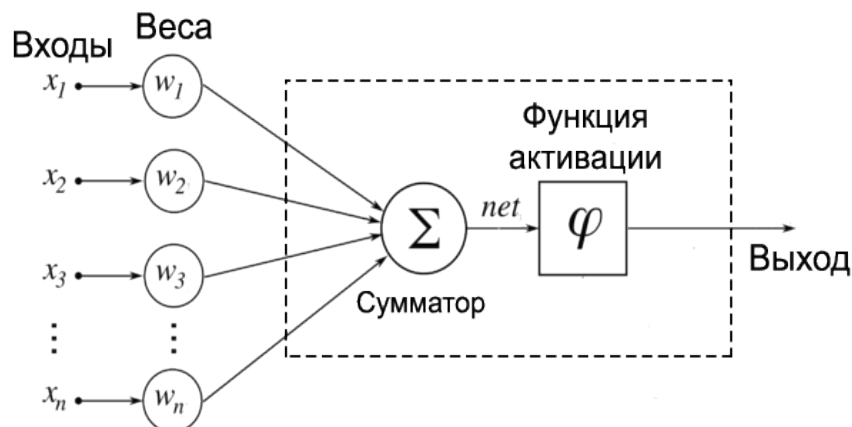


Рис. 5. Принципиальная схема работы искусственной нейронной сети

Принципиальная схема работы нейрона заключается в том, что в каждой единице одного уровня заложена одинаковая функция для обработки информации, но сигнал на стыке двух нейронов приобретает весовой коэффициент, который усиливает или ослабляет сигнал, за счет этого нейросети обладают стойкостью к «шумам» (к той информации, которая для решения задачи неважна) [12, 13].

#### 6. Стохастический градиентный спуск.

Алгоритмы градиентного спуска — это распространенный метод, применяемый в машинном обучении. Градиент — это в основном наклон функции; степень изменения параметра вместе с величиной изменения другого параметра. Математически это может быть описано как частные производные набора параметров относительно его входов. Чем больше уклон, тем круче склон.

Стохастический градиентный спуск означает систему или процесс, связанный со случайной вероятностью. Следовательно, в «Stochastic Gradient Descent» несколько выборок выбираются случайным образом вместо всего набора данных для каждой итерации.

#### Результаты

Выбор данных алгоритмов обусловлен тем, что эти методы являются наиболее подходящими для прогнозирования классов, поэтому другие алгоритмы (бустинг, метод опорных векторов, сети векторного квантования и др.) не были использованы, поскольку их цели — числовые значения.

Как было отмечено ранее, в Orange возможно использование визуального программирования (рис. 6) с помощью специальных виджетов, которые содержат готовые алгоритмы.

Затем были проведены вычисления с использованием нескольких алгоритмов и методов для отбора моделей, наиболее адекватно описывающих взаимосвязь качества крепления и оцениваемых показателей. Целью математического аппарата выбранных методов являлось прогнозирование (модель) оценки герметичности цементного камня (удовлетворительно/неудовлетворительно). Поскольку с небольшими базами данных лучше работают методы кластеризации, была выведена формула по переводу из численных показателей в категориальные значения [14–16], что было обусловлено относительно небольшим размером исходной выборки данных по скважинам.

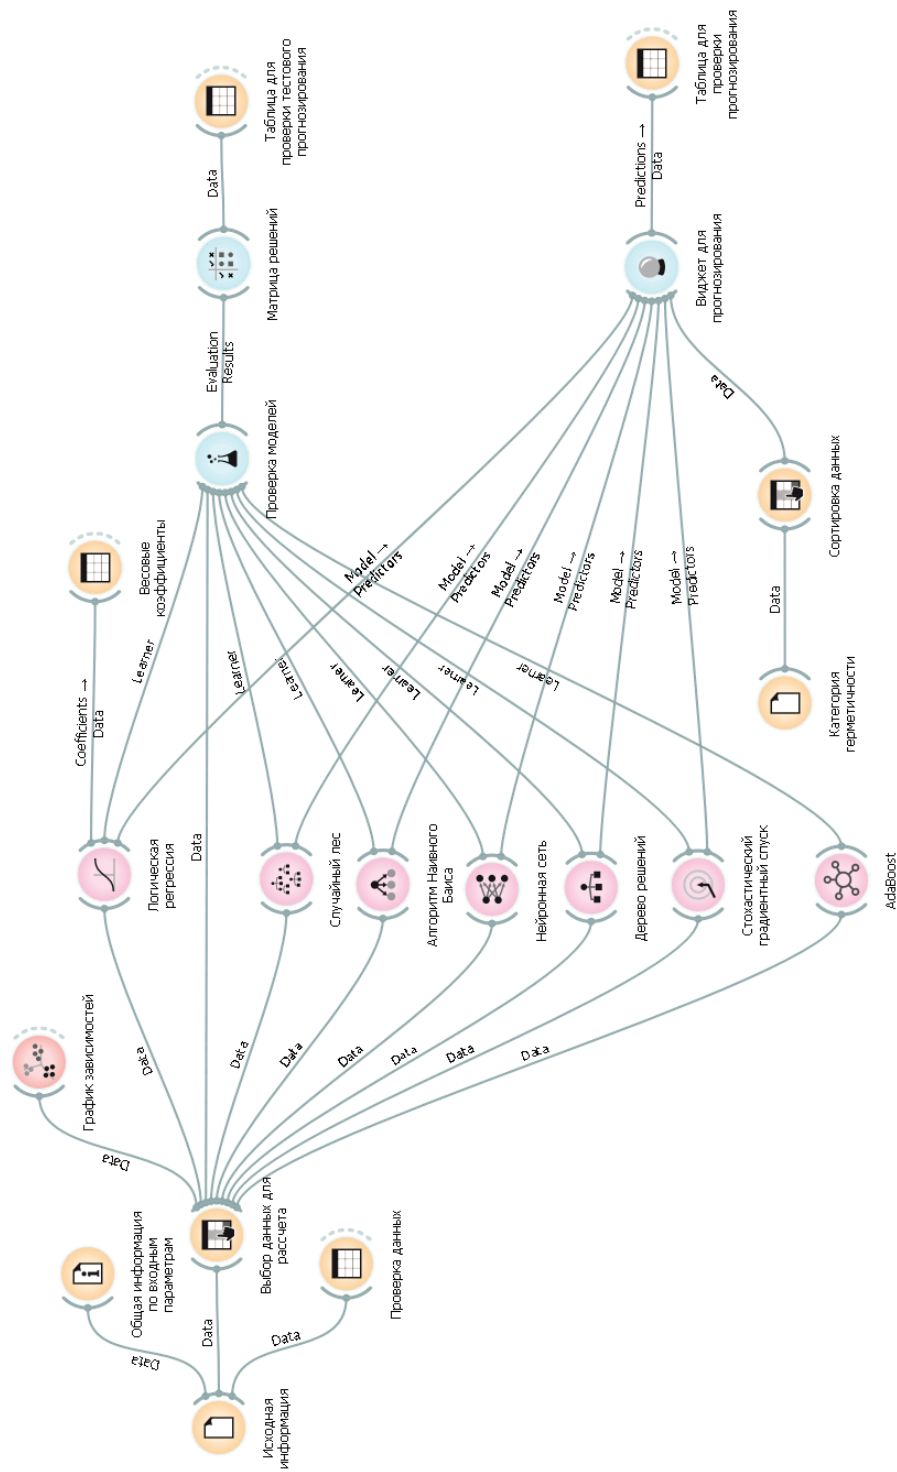


Рис. 6. Рабочий стол программного обеспечения Oganze

После загрузки исходной базы данных выбирается необходимая информация для «тренировки» математической модели, по результатам чего исключаются малозначимые параметры и параметры, напрямую влияющие на результат (например, на оценку герметичности влияют данные АКЦ и СГДТ) [17, 18]. Так, по данным, полученным в результате применения вычислительного аппарата логической регрессии, наибольшее положительное влияние на оценку герметичности оказывает «Давление «СТОП»» (коэффициент его «весомости» составляет 0,2332), следующим показателем является «Количество глубин промывок при спуске обсадной колонны» (0,1839), третий по величине оказываемого влияния — «Время до полного загустевания» (0,1394).

Наибольшее отрицательное влияние на удовлетворительную оценку герметичности цементного камня оказывают:

- «Рабочее давление цементирования» (–0,2200);
- «Расход бурового раствора при спуске обсадной колонны» (–0,1223);
- «Количество турбулизаторов» (–0,1114).

Результаты оценки качества методов показали (рис. 7), что наиболее точным является «Стохастический градиентный спуск» (доля правильных ответов — 0,808, точность — 0,802, полнота — 0,808), затем «Логическая регрессия» (доля правильных ответов — 0,781, точность — 0,767, полнота — 0,781).

Результаты					
	ППК	СА ▾	F1	Точность	Полнота
Стох. спуск	0.755	0.808	0.804	0.802	0.808
Логическая регр.	0.676	0.781	0.771	0.767	0.781
Случ. лес	0.501	0.753	0.647	0.568	0.753
Нейронная сеть	0.511	0.753	0.647	0.568	0.753
Лес решений	0.554	0.603	0.599	0.595	0.603
Метод Байеса	0.533	0.479	0.513	0.632	0.479

Рис. 7. Таблица оценки качества методов

Это подтверждается матрицей решений (рис. 8). Так, при анализе результатов применения алгоритма «Стохастический градиентный спуск» установлено, что было допущено 6 ошибок при прогнозировании «Неудовлетворительной герметичности» и 8 ошибок при прогнозировании удовлетворительного результата.

		Прогнозные значения		Σ
		неудовл	удовл	
Реальные значения	неудовл	49	6	55
	удовл	8	10	18
Σ		57	16	73

Рис. 8. Матрица решений метода стохастического градиентного спуска



Логическая регрессия (рис. 9) ошиблась при прогнозировании неудовлетворительного результата 6 раз и 10 раз при прогнозировании удовлетворительного результата оценки качества герметичности цементного камня.

		Прогнозные значения		$\Sigma$
		неудовл	удовл	
Реальные значения	неудовл	49	6	55
	удовл	10	8	18
$\Sigma$		59	14	73

Рис. 9. Матрица решений метода логической регрессии

После чего были скомпонованы новые фактические данные для тестирования оптимизированных математических моделей — была добавлена информация по скважине, параметры которой не учитывались при тренировке выбранных алгоритмов [19]. Заранее было установлено, что «Оценка герметичности» тестовой скважины была неудовлетворительной. Так, анализ результатов показал, что пять из шести алгоритмов дали правильный результат — неудовлетворительно:

- 1) стохастический градиентный спуск (вероятность правильного прогноза — 1);
- 2) логическая регрессия (0,99);
- 3) нейронная сеть (0,85);
- 4) случайный лес (0,77);
- 5) дерево решений (0,5).

Байесовский классификатор допустил ошибку — некорректный прогноз (вероятность неудовлетворительной оценки — 0,27). Объясняется это тем, что его математический аппарат нацелен на прогнозирование данных, подчиняющихся нормальному распределению вероятностей наступления того или иного события [20].

### Выводы

1. С помощью проведенного анализа параметров, влияющих на качество крепления скважины, было установлено, что для создания предиктивной модели на основе базы данных малого размера необходимо использовать методы кластеризации, поскольку их математический аппарат точно находит взаимосвязи исследуемых параметров и целевых классов.
2. Наиболее точными методами оказались «Стохастический градиентный спуск» и «Логическая регрессия». Это объясняется тем, что их алгоритмы являются эффективными в прогнозировании бинарных целевых параметров.
3. Предварительные результаты показали, что положительное влияние на герметичность цементного камня оказывают реология бездобавочного тампонажного раствора (время до полного загустевания, реология раствора средней плотности), технологические параметры промывки при спуске ОК («Давление «СТОП»», время проработки и промывки перед спуском ОК), геометрия ствола скважины и положение ОК в стволе (зенитный угол при входе в пласт, со-

осность ОК и ствола скважины); негативно сказываются на качестве крепления следующие параметры: давление промывки при спуске ОК, расход бурового раствора при спуске ОК, время спуска ОК, геометрия ствола скважины (величина несоосности на участке стабилизации, протяженность участка стабилизации), реология тампонажных (плотность бездобавочного раствора, время до полного загустевания тампонажного раствора средней плотности, растекаемость бездобавочного тампонажного раствора) и буровых растворов (условная вязкость и величина фильтрации).

4. Для формирования рекомендаций по повышению качества крепления скважин с использованием нейронных сетей в дальнейшем необходимо увеличить количество скважин в обрабатываемой выборке, детализацию факторов по каждому типу тампонажного раствора (для каждого будут свои оказывающие влияние показатели). Приобретенный опыт использования методов машинного обучения позволит в перспективе изменить подходы к оценке на проектной стадии решений, направленных на повышение герметичности крепи, путем выявления наиболее значимых параметров, которые оказывают значительное влияние на результат крепления скважин.

#### **Библиографический список**

1. Интегрированное решение по повышению качества крепления скважин в интервалах терригенных отложений / Р. Ф. Галиев, И. Р. Рафиков, А. В. Самсыкин [и др.]. – DOI 10.24887/0028-2448-2019-9-29-33. – Текст : непосредственный // Нефтяное хозяйство. – 2019. – № 9. – С. 29–33.
2. Оптимизация технико-технологических решений для строительства сложнопрофильных скважин / Д. Л. Бакиров, Э. В. Бабушкин, В. А. Бурдыга [и др.]. – DOI 10.30713/0207-2351-2019-8(608)-39-44. – Текст : непосредственный // Нефтепромысловое дело. – 2019. – № 8 (608). – С. 39–44.
3. Оптимизация затрат на бурение и обустройство месторождения в условиях геологической неопределенности / Д. Л. Бакиров, М. М. Фаттахов, Я.И.Баранников [и др.]. – DOI 10.30713/0130-3872-2018-10-22-28. – Текст : непосредственный // Строительство нефтяных и газовых скважин на суше и на море. – 2018. – № 10. – С. 22–28.
4. Снижение износа бурильных труб в скважинах со сложным профилем / Д. Л. Бакиров, В. А. Бурдыга, А. И. Доброчасов [и др.]. – DOI 10.30713/0130-3872-2018-10-33-38. – Текст : непосредственный // Строительство нефтяных и газовых скважин на суше и на море. – 2018. – № 10. – С. 33–38.
5. Бакиров, Д. Л. Предупреждение возникновения водоперетоков применением самовосстанавливающихся составов для крепления скважин / Д. Л. Бакиров, В. А. Бурдыга, В. Н. Ковалев. – Текст : непосредственный // Нефтяное хозяйство. – 2016. – № 8. – С. 36–39.
6. Разработка тампонажных растворов с цементозамещающими компонентами для крепления скважин в условиях Западной Сибири / Д. Л. Бакиров, В. А. Бурдыга, М. М. Фаттахов, Н. Р. Галеев. – Текст : непосредственный // Интервал. Передовые нефтегазовые технологии. – 2009. – № 2. – С. 43–45.
7. Повышение устойчивости крепи скважины динамическому воздействию / Д. Л. Бакиров, В. А. Бурдыга, М. М. Фаттахов [и др.]. – DOI 10.30713/0207-2351-2020-1(613)-65-70. – Текст : непосредственный // Нефтепромысловое дело. – 2020. – № 1. – С. 65–70.
8. К вопросу оценки качества крепления скважин / Д. Л. Бакиров, В. А. Бурдыга, М. М. Фаттахов, Г. Н. Грицай. – DOI 10.30713/0207-2351-2019-9(609)-10-13. – Текст : непосредственный // Нефтепромысловое дело. – 2019. – № 9 (609). – С. 10–13.
9. Data-driven model for the identification of the rock type at a drilling bit / N. Klyuchnikov, A. Zaytsev, A. Gruzdev [et al.]. – DOI 10.1016/j.petrol.2019.03.041. – Текст : непосредственный // Journal of Petroleum Science and Engineering. – 2019. – Vol. 178. – P. 506–516.

10. Cayeux, E. Toward Drilling Automation: On the Necessity of Using Sensors That Relate to Physical Models / E. Cayeux, B. Daireaux, E. W. Dvergsnes, F. Florence. – DOI 10.2118/163440-PA. – Текст : непосредственный // SPE Drilling & Completion. – 2014. – Vol. 29, Issue 02. – P. 236–255.
11. Chen, T. XGBoost: A scalable tree boosting system / T. Chen, C. Guestrin. – Текст : непосредственный // Proceedings of the 22<sup>nd</sup> ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. – 2016. – P. 785–794.
12. Downton, G. C. Challenges of Modeling Drilling Systems for the Purposes of Automation and Control / G. C. Downton. – DOI 10.3182/20120531-2-NO-4020.00054. – Текст : непосредственный // IFAC Proceedings Volumes. – 2012. – P. 201–210.
13. Detournay, E. A phenomenological model for the drilling action of drag bits / E. Detournay, P. Defourny. – DOI 10.1016/0148-9062(92)91041-3. – Текст : непосредственный // International Journal of Rock Mechanics and Mining Sciences & Geomechanics. – 1992. – Vol. 29. – P. 13–23.
14. Современный опыт заканчивания облепченных конструкций горизонтальных скважин / Д. Л. Бакиров, М. М. Фаттахов, В. А. Бурдыга [и др.]. – Текст : непосредственный // Геология, геофизика и разработка нефтяных и газовых месторождений. – 2016. – № 11. – С. 48–53.
15. Совершенствование технологии строительства боковых стволов с горизонтальным окончанием в сложных геолого-технических условиях / Д. Л. Бакиров, Г. В. Мазур, Э. В. Бабушкин [и др.]. – DOI 10.24887/0028-2448-2019-8-40-43. – Текст : непосредственный // Нефтяное хозяйство. – 2019. – № 8. – С. 40–43.
16. Фаттахов, М. М. Оптимизация профилей скважин с большой протяженностью горизонтального участка / М. М. Фаттахов, И. К. Ахметшин. – Текст : непосредственный // Бурение и нефть. – 2012. – № 8. – С. 42–44.
17. Планирование и строительство многозабойных скважин с большим отходом по вертикали / Д. Л. Бакиров, И. К. Ахметшин, М. М. Фаттахов [и др.]. – Текст : непосредственный // Геология, геофизика и разработка нефтяных и газовых месторождений. – 2015. – № 9. – С. 41–50.
18. Бакиров, Д. Л. Опыт строительства скважин сложной архитектуры на месторождениях ОАО «ЛУКОЙЛ» в Западной Сибири / Д. Л. Бакиров, М. М. Фаттахов, Л. С. Бондаренко. – Текст : электронный // Российская техническая нефтегазовая конференция и выставка SPE по разведке и добыче (Москва, 14–16 октября 2014 г.). – URL: <https://doi.org/10.2118/171264-ru>.
19. Фаттахов, М. М. Классификатор многозабойных и многоствольных скважин / М. М. Фаттахов. – Текст : непосредственный // Строительство нефтяных и газовых скважин на суше и на море. – 2015. – № 4. – С. 22–24.
20. Бурение наклонных и горизонтальных скважин : справочник / А. Г. Калинин, Б. А. Никитин, К. М. Солодкий, Б. З. Сулганов. – Москва : Недра, 1997. – 647 с. – Текст : непосредственный.

### References

1. Galiev, A. F., Rafikov, I. R., Samsykin, A. V., Mardaganiev, T. R., & Agzamov, F. A. (2019). Integrated solution to the issue of improving the quality of well casing in terrigenous sediments. *Oil Industry*, (9), pp. 29-33. (In Russian). DOI: 10.24887/0028-2448-2019-9-29-33
2. Bakirov, D. L., Babushkin, E. V., Burdyga, V. A., Fattakhov, M. M., Shcherbakov, A. V., & Dobrochasov, A. I. (2019). Optimization of technical-technological solutions for construction of complex-profile wells. *Oilfield Engineering*, (8(608)), pp. 39-44. (In Russian). DOI: 10.30713/0207-2351-2019-8(608)-39-44
3. Bakirov, D. L., Fattakhov, M. M., Barannikov, Ya. I., Vityaz, A. V., & Abdrakhmanov, R. R. (2018). Optimization of drilling costs and construction of a field facilities in conditions of geological uncertainty. *Construction of Oil and Gas Wells on Land and Sea*, (10), pp. 22-28. (In Russian). DOI: 10.30713/0130-3872-2018-10-22-28
4. Bakirov, D. L., Burdyga, V. A., Dobrochasov, A. I., Fattakhov, M. M., & Fatihov, V. V. (2018). Reduction of drilling pipes wear-out in wells with a complex profile. *Construction of Oil and Gas Wells on Land and Sea*, (10), pp. 33-38. (In Russian). DOI: 10.30713/0130-3872-2018-10-33-38

5. Bakirov, D. L., Burdyga, V. A., & Kovalev, V. N. (2016). Water cross flows appearance preventing with application of self-healing compositions for cementing. *Oil Industry*, (8), pp. 36-39. (In Russian).
6. Bakirov, D. L., Burdyga, V. A., Fattakhov, M. M., & Galeev, N. R. (2009). Razrabotkatamponazhnykh rastvorov s tsementozameshchayushchimi komponentami dlya krepleniya skvazhin v usloviyakh Zapadnoy Sibiri. *Interval. Peredovye neftegazovye tekhnologii*, (2), pp. 43-45. (In Russian).
7. Bakirov, D. L., Burdyga, V. A., Fattakhov, M. M., Gritsay, G. N., Belousov, A. O., & Antonov, V. V. (2020). Increase of a well cementing stability to dynamic influence. *Oilfield Engineering*, (1), pp. 65-70. (In Russian). DOI: 10.30713/0207-2351-2020-1(613)-65-70
8. Bakirov, D. L., Burdyga, V. A., Fattakhov, M. M., & Gritsay, G. N. (2019). To the problem of the assessment of wells cementing quality. *Oilfield Engineering*, (9(609)), pp. 10-13. (In Russian). DOI: 10.30713/0207-2351-2019-9(609)-10-13
9. Klyuchnikov, N., Zaytsev, A., Gruzdev, A., Ovchinnikov, G., Antipova, K., Ismailova, L.,... Koroteev, D. (2019). Data-driven model for the identification of the rock type at a drilling bit. *Journal of Petroleum Science and Engineering*, 178, pp. 506-516. (In English). DOI: 10.1016/j.petrol.2019.03.041
10. Cayeux, E., Daireaux, B., Dvergsnes, E. W., & Florence, F. (2014). Toward Drilling Automation: On the Necessity of Using Sensors That Relate to Physical Models. *SPE Drilling & Completion*, 29(02), pp. 236-255. (In English). DOI: 10.2118/163440-PA
11. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22<sup>nd</sup> ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785-794. (In English).
12. Downton, G. C. (2012). Challenges of Modeling Drilling Systems for the Purposes of Automation and Control. *IFAC Proceedings Volumes*, pp. 201-210. (In English). DOI: 10.3182/20120531-2-NO-4020.00054
13. Detournay, E., & Defourny, P. (1992). A phenomenological model for the drilling action of drag bits. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics*, 29, pp. 13-23. (In English). DOI: 10.1016/0148-9062(92)91041-3
14. Bakirov, D. L., Fattahov, M. M., Burdyga, V. A., Babushkin, E. V., Volokitin, D. N., Kovalev, V. N.,... Yunusov, R. R. (2016). Modern experience of completion of horizontal wells' lightweighted constructions. *Geology, Geophysics and Development of Oil and Gas Fields*, (11), pp. 48-53. (In Russian).
15. Bakirov, D. L., Mazur, G. V., Babushkin, E. V., Bagaev, P. A., & Ovchinnikov, V. P. (2019). Improving technology of horizontal sidetracking in complicated geological-technical conditions. *Oil Industry*, (8), pp. 40-43. (In Russian). DOI: 10.24887/0028-2448-2019-8-40-43
16. Fattahov, M. M., & Akhmetshin, I. K. (2012). Optimization of profiles of wells with great length of horizontal section. *Burenieineft'*, (8), pp. 42-44. (In Russian).
17. Bakirov, D. L., Akhmetshin, I. K., Fattakhov, M. M., Babushkin, E. V., Chertentkov, M. V., & Kovalev, V. N. (2015). Planning and construction of extended-reach multilateral wells. *Geology, Geophysics and Development of Oil and Gas Fields*, (9), pp. 41-50. (In Russian).
18. Bakirov, D. L., Fattakhov, M. M., & Bondarenko, L. S. (2014). Practice of Complex Architecture Well Construction at the Oil Fields of OAO Lukoil in Western Siberia (Russian). *SPE Russian Oil and Gas Exploration & Production Technical Conference and Exhibition*, 14-16 October, Moscow, Russia. (In Russian). Available at: <https://doi.org/10.2118/171264-ru>
19. Fattakhov, M. M. (2015). Classifier of splitters and multi-lateral wells. *Construction of Oil and Gas Wells on Land and Sea*, (4), pp. 22-24. (In Russian).
20. Kalinin, A. G., Nikitin, B. A., Solodkiy, K. M., & Sultanov, B. Z. (1997). *Burenie naklonnykh i gorizontal'nykh skvazhin*. Moscow, Nedra Publ., 647 p. (In Russian).

#### **Сведения об авторах**

**Шалыпин Денис Валерьевич**, аспирант, Тюменский индустриальный университет, инженер 2 категории отдела научно-исследовательских работ по буровым и тампонажным растворам, филиал ООО «ЛУКОЙЛ-Инжиниринг» «КогалымНИ-Пинефть», г. Тюмень

#### **Information about the authors**

**Denis V. Shalyapin**, Postgraduate, Industrial University of Tyumen, Engineer of the 2<sup>nd</sup> grade at the Department of the Research Works in Drilling and Cement Muds, KogalymNI-Pineft Branch of LUKOIL-Engineering LLC, Tyumen

**Бакиров Данияр Лябинович**, к. т. н., заместитель директора филиала, филиал ООО «ЛУКОЙЛ-Инжиниринг» «КогалымНИПИнефть», г. Тюмень

**Фаттахов Марсель Масалимович**, начальник отдела научно-исследовательских работ по буровым и тампонажным растворам, филиал ООО «ЛУКОЙЛ-Инжиниринг» «КогалымНИПИнефть», г. Тюмень

**Шаляпина Аделя Данияровна**, аспирант, ассистент кафедры бурения нефтяных и газовых скважин, Тюменский индустриальный университет, г. Тюмень, e-mail: shaljarinaad@tyuiu.ru

**Мелехов Александр Васильевич**, старший научный сотрудник отдела научно-исследовательских работ по буровым и тампонажным растворам, филиал ООО «ЛУКОЙЛ-Инжиниринг» «КогалымНИПИнефть», г. Тюмень

**Щербakov Андрей Валерьевич**, начальник отдела проектирования и реконструкции скважин, филиал ООО «ЛУКОЙЛ-Инжиниринг» «КогалымНИПИнефть», г. Тюмень

**Кузнецов Владимир Григорьевич**, д. т. н., профессор кафедры бурения нефтяных и газовых скважин, Тюменский индустриальный университет, г. Тюмень

**Daniyar L. Bakirov**, Candidate of Engineering, Assistant Director of Branch, KogalymNIPIneft Branch of LUKOIL-Engineering LLC, Tyumen

**Marsel M. Fattahov**, Head of the Department of the Research Works in Drilling and Cement Muds, KogalymNIPIneft Branch of LUKOIL-Engineering LLC, Tyumen

**Adelya D. Shalyapina**, Postgraduate, Assistant at the Department of Drilling Oil and Gas Wells, Industrial University of Tyumen, e-mail: shaljarinaad@tyuiu.ru

**Alexander V. Melekhov**, Senior Researcher at the Department of the Research Works in Drilling and Cement Muds, KogalymNIPIneft Branch of LUKOIL-Engineering LLC, Tyumen

**Andrey V. Sherbakov**, Head of the Department of Design and Reconstruction of Wells, KogalymNIPIneft Branch of LUKOIL-Engineering LLC, Tyumen

**Vladimir G. Kuznetsov**, Doctor of Engineering, Professor at the Department of Drilling Oil and Gas Wells, Industrial University of Tyumen