

УДК 004.8.622.24

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ РЕОЛОГИЧЕСКИХ ПАРАМЕТРОВ БУРОВОГО РАСТВОРА

Третьяк Александр Яковлевич¹,
13050465@mail.ru

Кузнецова Алла Витальевна¹,
alvitkuz@yandex.ru

Борисов Константин Андреевич¹,
13020165@mail.ru

Карельская Екатерина Витальевна¹,
karelskaya_1992@mail.ru

¹ Южно-Российский государственный политехнический университет (НПИ) им. М.И. Платова,
Россия, 346428, г. Новочеркасск, ул. Просвещения, 132.

Актуальность исследования обусловлена тем, что дифференциальные прихваты являются одной из самых сложных аварий во всей технологической цепочке строительства нефтяных и газовых скважин. Качественный и правильно подобранный буровой раствор с оптимальной для конкретных условий бурения реологией является одним из определяющих факторов предупреждения дифференциальных прихватов.

Цель: разработка нейросетевой реологической модели бурового раствора на основе его компонентного состава и результатов периодических замеров выходных параметров промывочной жидкости. С помощью нейронной сети можно достаточно точно и быстро прогнозировать значения реологических свойств раствора, которые оказывают существенное влияние на возникновение и предотвращение дифференциальных прихватов.

Объектом исследования являются нейросетевые реологические модели бурового раствора, буровые растворы, состав которых оказывает влияние на реологические свойства и на возможность предотвращения дифференциальных прихватов буровой колонны в процессе сооружения скважины.

Методы: нейросетевая модель различающихся по числу и составу входных параметров буровых растворов.

Результаты. Дано описание процесса обучения трех нейронных сетей на основе оперативных данных, получаемых на буровых для замера параметров бурового раствора. Предложено шесть типов буровых растворов, которые являются оптимальными для конкретных геологических условий. Введение в состав бурового раствора с высокой смазывающей способностью нанодисперсной меди и алюмината калия способствует уменьшению коэффициента трения, повышению ингибирующей способности раствора, уменьшению водоотдачи и, как результат, резкому уменьшению дифференциальных прихватов в процессе сооружения скважин на углеводородное сырье.

Ключевые слова:

Дифференциальный прихват колонны буровых труб, прогноз прихватов, буровой наноструктурированный раствор, искусственные нейронные сети, нейросетевая модель бурового раствора.

Введение

Сооружение скважины – трудоемкий инженерно-технологический процесс, нередко осложняющийся различного рода авариями, которые снижают производительность труда и повышают себестоимость буровых работ. Известно, что порядка 30 % всех осложнений приходится на дифференциальные прихваты. Дифференциальный прихват происходит в интервалах проницаемых пластов – песчаников, алевроитов, мела – при значительном проникновении компонентов бурового раствора в поровые пространства стенок скважины. Одной из предпосылок возникновения дифференциального прихвата является использование глинистого раствора с повышенной фильтрацией и образованием толстой корки с плохими смазывающими свойствами. Находящаяся в неподвижном состоянии буровая колонна прижимается к стенке скважины и вдавливаются в глинистую корку. Трение между колонной и породой пласта возрастает настолько, что сдвинуть её с места, не прилагая специальных действий, становится невозможно. При

этом зачастую имеет место непрекращающаяся циркуляция бурового раствора, если прихвату не предшествовало поглощение.

При исследовании факторов, влияющих на величину силы дифференциального прихвата бурового инструмента, установлено, что существенную роль в его предотвращении играет грамотный выбор компонентного состава бурового раствора в соответствующих геологических условиях. Реология бурового раствора является определяющим фактором для повышения эффективности очистки скважины и оптимизации производительности бурения [1, 2]. Реологические параметры бурового раствора оказывают непосредственное влияние на период образования, толщину, проницаемость и другие характеристики глинистой корки, а значит, на скорость возникновения прихвата, площадь контакта и силу сцепления бурового инструмента с фильтрационной коркой.

Идеальной может считаться тонкая, твердая фильтрационная корка, образовавшаяся только из твердой фазы бурового раствора. И чем быстрее корка станет

непроницаемой, тем меньший объем фильтрата попадет в пласт. Эффективная фильтровальная корка становится непроницаемой из-за тонких отложений твердых частиц и останавливает дальнейшее поступление фильтрата в глинистую породу, несмотря на превышение баланса (рис. 1, а). Если в буровом растворе накапливаются крупные твердые частицы, такие как песок, фильтрующие свойства бурового раствора ухудшаются.

При этом накапливается более толстый осадок твердых частиц, и корка никогда не может стать полностью непроницаемой. В этом случае гидростатическое давление заставит фильтрат течь в поровые пространства породы, и проницаемому пласту будет оказываться мало поддержки с точки зрения укрепления стенок скважины. Крупные твердые частицы увеличивают толщину фильтрационной корки (рис. 1, б).




Рис. 1. Образование тонкой (а) и толстой (б) фильтрационной корки
Fig. 1. Thin (a) and thick (b) filter cake formation

Мониторинг состава бурового раствора в процессе проводки скважины

Уменьшение контактной площади, снижение коэффициента трения между колонной и образующейся коркой, повышение её качества можно достичь за счет подбора свойств промывочной жидкости. Поэтому разработка рационального состава бурового раствора при проводке скважин в глинистых отложениях с геологического разреза скважин является актуальной научно-технической задачей, требующей эффективного решения.

Непрерывный и качественный мониторинг реологических свойств бурового раствора в период проведения буровых работ оказывает существенное влияние на эффективность бурения. Для повышения показателей производительности необходимы непрерывные измерения свойств бурового раствора, которые выполняются на буровой, оснащенной необходимыми лабораторными инструментами. Обычная полевая практика включает только измерение плотности и вязкости бурового раствора с периодичностью 15–20 минут. Полное же исследование бурового раствора для оценки его реологии проводится два раза в день, требуя соответствующего оборудования, значительного времени и необходимых реагентов. И, к тому же, подвержено человеческим ошибкам. Поэтому автоматизация этого процесса с использованием алгоритмов прогнозирования необходима буровой промышленности для преодоления проблем измерения реологии с более высокой частотой.

В последнее десятилетие прогнозирование свойств бурового раствора всё больше основывается на методах и технологиях искусственного интеллекта в про-

тивовес использованию стандартных моделей бурового раствора, таких как модель Бингама, модель степенного закона О. де Ваэля, Гершеля–Бакли, Чеушнера [3], применяющихся в статистических лабораторных тестах. Существенное место в новых исследованиях занимают искусственные нейронные сети (ИНС) [4–11]. Обученная на качественных наборах исторических данных нейронная сеть способна предсказывать трудно определяемые реологические параметры в считанные секунды и с приемлемой точностью.

Предлагаемые нейросетевые модели различаются по числу и составу входных и выходных параметров, по типам буровых растворов – на водной или нефтяной основе, по типам и архитектурам используемых нейронных сетей. Но в качестве исходных характеристик в подавляющем большинстве работ [4–6, 11–13] используются: плотность бурового раствора (Mud Density, MD), вязкость по воронке (Marsh Funnels Viscosity, FV), содержание твёрдой фазы, температура бурового раствора, которые представляют собой легкодоступные полевые данные. А выходными, искомыми параметрами моделей чаще всего выступают: пластическая вязкость (Plastic Viscosity, PV), предел текучести (Yield Point, YP) и эффективная, или кажущаяся, вязкость (Apparent Viscosity, AV). Пластическая вязкость указывает на количество твёрдых частиц, присутствующих в буровом растворе. Их неконтролируемое увеличение может привести ко многим критическим проблемам при бурении. Предел текучести характеризует силу притяжения между коллоидными частицами в буровом растворе. Соотношение YP/PV и последующая оптимизация YP существенно влияет на эффективность очистки скважины и предотвращение возникающих проблем [14]. Чем выше значения AV,

тем лучше вымывается шлам. Однако существенный рост кажущейся вязкости чреват увеличением гидравлических сопротивлений при течении бурового раствора в кольцевом пространстве, а значит, и увеличением дифференциального давления.

В работе [6] описан процесс обучения трёх нейронных сетей для определения PV, YP и AV на основе оперативных данных о балансе и вязкости бурового раствора, измеряемых каждые 15–20 минут с помощью воронки Марша. При этом авторы предлагают после обучения воспользоваться не самой нейронной сетью с одним скрытым слоем, а эмпирическими уравнениями, в состав которых входят значения весовых коэффициентов и смещений нейронов обученной сети. Похожие работы [5, 11] описывают процесс нейросетевого прогнозирования расширенного набора реологических параметров, включающего индекс консистенции бурового раствора и индекс несущей способности. Прогноз осуществляется на основе MD, FV и проценте твёрдого вещества, выходящего из скважины бурового раствора. В [4] авторы рекомендуют определять пластическую вязкость, предел текучести, индекс поведения потока и кажущуюся вязкость на основе массы бурового раствора и вязкости на воронке Марша, но предлагают исключить из входных данных четырёх нейросетевых моделей процентное содержание твёрдого вещества, поскольку, по их мнению, его влияние на искомые реологические параметры несущественно, а время определения достаточно затратное. В [13] показано, что именно нейросетевая модель наилучшим образом осуществляет прогнозирование пластической вязкости, статического напряжения сдвига СНС 1 и СНС 10 по сравнению с другими методами машинного обучения, такими как многомерный линейный регрессионный анализ, дерево решений, метод опорных векторов и др.

Подводя итоги обзора в области нейросетевого моделирования реологии буровых растворов, можно сделать вывод о том, что развитие этого направления может идти по пути усложнения модели и учета в качестве входных параметров не только данных полевых измерений, но и компонентного состава промывочной жидкости. Формализовать влияние того или иного компонента на искомые реологические характеристики стандартными статистическими методами не представляется возможным. А ИНС могут улучшить качество прогноза реологии буровых растворов в силу своей природной способности улавливать и учитывать нелинейные взаимосвязи между входными и выходными параметрами.

Многокомпонентные высоко ингибирующие буровые растворы

Проведенные кафедрой нефтегазовых техники и технологий ЮРГПУ (НПИ) лабораторные испытания позволили оценить реологические свойства шести разновидностей бурового раствора, отличающихся составом и исходным объемом входящих в него компонентов (табл. 1). Каждый из шести предлагаемых буровых растворов разработан для условий юга Крас-

нодарского края, где разрез представлен вязкими, неустойчивыми, пучащими глинами. Наиболее эффективным оказался высокатионно-ингибированный буровой раствор [15].

При достаточно широком процентом диапазоне варьирования химреагентами мы попытались, используя нейросетевое моделирование, прогнозировать оптимальные реологические параметры бурового раствора с целью существенного уменьшения частоты дифференциальных прихватов, имеющих место в этом районе и достигающих 30 % от общего времени на сооружение скважин.

Химический состав и объемы базовых компонентов представленных растворов имеют ряд различий, но основные свойства растворов говорят об их высоком качестве и способности формировать тонкую и прочную корку.

Таблица 1. Входные и выходные данные нейросетевой модели

Table 1. Neural network model input and output data

Название раствора, номер патента Drilling mud name, patent number	Параметры/Data	
	Входные Input	Выходные Output
Высокоингибированный, инвертный буровой раствор Highly inhibited, invert drilling mud [16]	Массовое содержание компонентов бурового раствора Drilling mud components weight content	Плотность Density
Высокоингибированный буровой раствор Highly inhibited drilling mud [17]		Вязкость/Viscosity
Буровой раствор Drilling mud [18]		Водоотдача Filtration
Наноструктурированный, высокоингибированный буровой раствор Nanostructured, highly inhibited drilling mud [19]		СНС 1 минута Gel strength 1 min
Высокатионно-ингибированный буровой раствор Highly cation-inhibited drilling mud [15]		СНС 10 минут Gel strength 10 min
Эмульсионно-ингибированный, реверсивно-инвертный буровой раствор Emulsion-inhibited, reversible-invert drilling mud [20]		pH
		Липкость/Stickability
		Толщина корки Filter cake thickness
		Содержание песка Mud sand content

Минимальное количество дифференциальных прихватов было зарегистрировано при бурении на высокоингибированном наноструктурированном буровом растворе с высокой степенью щелочности в осложненных условиях залегания глинистых почв месторождений Краснодарского края [19].

Нейросетевая модель структурированного бурового раствора

Для эффективного расхода дорогостоящих ингредиентов необходимо сформировать совокупную модель, способную оценивать влияние состава и процентного соотношения компонентов промывочной жидкости. Применение результатов моделирования напрямую связано с прогнозированием возникновения осложнений при бурении и, в частности, с прогнозированием дифференциальных прихватов.

Отсутствие априорного формального описания природы и характера зависимостей искомых реологических свойств от качества и количества исходных ингредиентов обуславливает выбор нейросетевых технологий для прогнозирования параметров бурового раствора, т. е. решения задачи множественной регрессии. Нейросетевая реализация регрессионной модели имеет преимущество перед классической множественной регрессией в способности воссоздания регрессионной функции с большим количеством входных переменных («проклятия размерности») и лучшей аппроксимацией существенно нелинейных зависимостей между выходным значением и входными параметрами.

ИНС со сложной многослойной архитектурой (рис. 2) способна вычислять сразу несколько выходных значений по одному и тому же набору исходных данных:

$$p_{reol_k} = F_k(c_1, \dots, c_i, \dots, c_N, p_{mes_1}, \dots, p_{mes_j}, \dots, p_{mes_M}),$$

где p_{reol_k} – k -й выходной реологический параметр, $k=1..K$; k – количество искомых выходных параметров раствора; c_i – процентное содержание i -го компонента, $i=1..N$, N – количество используемых компонентов раствора; p_{mes_j} – измеренная характеристика бурового раствора, $j=1..M$, M – число измеренных характеристик раствора.

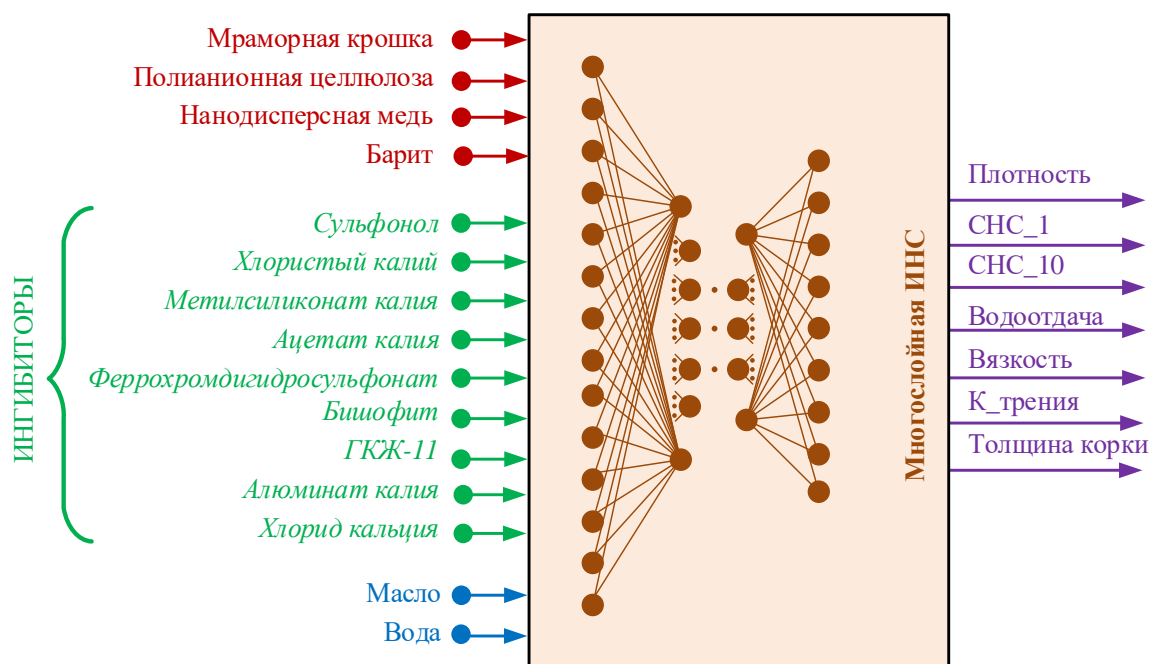


Рис. 2. Многослойная искусственная нейронная сеть для вычисления совокупности реологических параметров
Fig. 2. Multilayer artificial neural network for rheological parameters complex calculation

Однако разделение одной, но достаточно сложной, ИНС на совокупность из K более простых по архитектуре сетей, объединенных в общую систему (ансамбль), позволяет решать задачу вычисления значения функции многих переменных на более качественном уровне. Отдельная ИНС, входящая в ансамбль, теоретически обладает более высокой прогнозирующей способностью, и для её обучения достаточно небольшого объема данных по сравнению с объемами данных, требующимися для одной универсальной сети со сложной структурой [21, 22].

Учитывая вышесказанное и высокую сложность синергетического взаимодействия компонентов бурового раствора, выбор типа модели был сделан в пользу ансамбля многослойных нейронных сетей типа перцептрон (Many Layers Perceptron, MLP). Применение универсальных многослойных сетей прямого распространения сигнала для решения слабо формализуемых задач в области отечественной и зарубежной нефте- и газодобычи хорошо зарекомендовало себя не только в области диагностирования реологии буровых растворов, но и в части прогнозирования

различных аварийных и предаварийных ситуаций [23–25].

На рис. 3, 4 представлены ансамбль и соответствующие архитектуры ИНС перцептронного комплекса, отображающие выявленные зависимости между компонентным составом и свойствами бурового раствора.

Входные параметры модели представляют собой нормированные к диапазону $[-1..1]$ процентные соотношения компонентов бурового раствора (№ 4, табл. 1) на водно-масляной основе. Выходные параметры модели – это вышеописанные свойства бурового раствора, оказывающие наибольшее влияние на процесс возникновения дифференциальных прихватов. В состав ансамбля входит шесть нейронных сетей с одним или двумя скрытыми слоями, нейроны которых имеют нелинейную функцию активации – гиперболический тангенс (tansig); выходным слоем из 1, 2 или 3-х нейронов с линейной функцией активации (purelin). Используемый алгоритм обучения сети – быстро сходящийся алгоритм Левенберга–Маркварта (trainlm). Реализация и исследование моделей проведено в среде Neural Networks Toolbox системы MatLab [26].






Рис. 3. Нейросетевая ансамблевая модель реологии бурового раствора

Fig. 3. Neural network assembles model of drilling mud rheology


ИНС_1 для вычисления плотности




ИНС_4 для вычисления CHC_1, CHC_10




ИНС_2 для вычисления водоотдачи



ИНС_5 для вычисления толщины корки



ИНС_3 для вычисления вязкости



ИНС_6 для вычисления коэффициента трения




Рис. 4. Архитектуры перцептронов нейросетевого ансамбля

Fig. 4. Neural network ensemble perceptron's architectures

Экспериментальным путём по итогам обучения, а также на основе анализа характера процесса обучения было выбрано по 6 предположительно наиболее эффективных сетей различных структур для каждого из шести выходных параметров.

Формирование обучающего множества

Для построения нелинейной модели бурового раствора на основе методов машинного обучения потребовался достаточно большой объём исходных данных – так называемая обучающая выборка, или обучающее множество. Под термином «достаточно большой» следует понимать, что уже для создания простой (линейной) регрессионной модели, включающей 10 факторов, может потребоваться от одной до двух сотен примеров [27]. В случае построения нелинейных моделей машинного обучения на базе ИНС часто используется эмпирическое «правило 2–5», согласно которому число экземпляров обучающей выборки должно в 2–5 раз превышать количество межнейронных связей MLP для эффективного формирования её моделирующих способностей. Если это соотношение будет близко к единице, то нейронная сеть в основном просто запомнит обучающую выборку и не сможет извлечь из неё закономерности. Например, для нейронной сети с пятью входами, двумя выходами и одним скрытым слоем из десяти нейронов (архитектура «5–10–2») количество межнейронных связей будет равно $10 \cdot 5 + 2 \cdot 10 = 70$, а рекомендуемый объём обучающей выборки будет варьироваться в диапазоне [140...350] элементов.

Такими объемами экспериментальных данных для построения модели бурового раствора авторы не располагают. Недостаток обучающих примеров вида «вектор компонентов – вектор свойств» был компенсирован с помощью так называемого метода приращения данных, для которого имеющиеся данные лабораторных испытаний десяти базовых растворов могут выступать в качестве основы для создания синтетического обучающего множества. Сравнительно небольшой объём экспериментальных данных был расширен за счёт применения процедуры искусственной генерации обучающих данных под названием SMOTE (Synthetic Minority Oversampling TEchnique) [28]. Изначально алгоритм был предназначен для увеличения объемов слабо представленных (миноритарных) классов в несбалансированной выборке при решении задач бинарной классификации. В основе алгоритма лежит идея искусственного воссоздания некоторого количества объектов \tilde{x} , которые были бы «похожи» на объекты x , представленные в обучающей выборке X . Вновь синтезируемые объекты не дублируют уже имеющиеся объекты, а расширяют набор данных на основе принципа «геометрической близости» в многомерном пространстве. Эта процедура направлена на повышение качества модели машинного обучения.

Предлагаемый алгоритм был адаптирован к имеющимся экспериментальным данным по десяти буровым растворам для решения задачи увеличения репрезентативности обучающей выборки. Весь набор

данных интерпретировался как миноритарный класс с элементами, упорядоченными по возрастанию общего количества присадок в водно-масляной основе. В качестве опорных экземпляров x_i использовались восемь растворов с номерами №№ 2–9. А в качестве двух ближайших соседей x_{i+1} и x_{i-1} выступала пара выше- и нижеследующих элементов, векторные расстояния $d_1 = |x_i - x_{i-1}|$ и $d_2 = |x_{i+1} - x_i|$ до которых изначально являются минимальными. Для создания каждого синтетического объекта, расположенного рядом с опорным вектором, согласно [2, 28], каждый элемент вектора разности d , умноженный на случайное число из диапазона $[0...q]$, суммировался с соответствующим элементом опорного образца x_a . Значение параметра q определяется как $\frac{1}{4}$ от соответствующего элемента вектора d . Таким образом генерируется синтетический вектор \tilde{x}_a , входящий в состав обучающего множества. Каждый искусственно сгенерированный образец при этом оказывается размещенным внутри многомерного пространства между двумя реальными образцами – базовым и его ближайшим соседом. По утверждению авторов, применение алгоритма позволяет получить лучшие результаты по сравнению с традиционной выборкой с повторениями или случайными значениями из диапазона изменения каждого элемента вектора x . Схема, иллюстрирующая процесс генерации синтетического вектора на примере базовых векторов № 1 и № 2 и случайного числа 0,25, представлена в табл. 2.

Объём генерируемого набора данных определялся из соотношения:

$$|X| = 2 \cdot (N - 2) \cdot M,$$

где $|X|$ – мощность (объём) обучающего множества; N – число опорных векторов; M – число генерируемых векторов в обе стороны от опорного вектора. Так, если число искусственно генерируемых образцов от опорного вектора до каждого соседнего вектора равно десяти, то на базе исходного множества из элементов будет сформировано множество из $2 \cdot (10 - 2) \cdot 10 = 160$ экземпляров. Варьируя величину M , можно получать обучающие множества разной мощности, соответствующей вышеописанному «правилу 2–5». Сами же исходные данные по десяти базовым растворам в состав обучающего множества при этом не войдут, а будут использоваться в качестве идеального/окончательного тестового множества для оценки и интерпретации создаваемой модели.

Для оценки и сравнения прогнозирующих способностей полученных моделей была использована выборка из 10 реальных растворов, которые не участвовали в обучении. Исходя из того, что разброс измерений реологических свойств раствора в лабораторных исследованиях находится в пределах 5 %, ансамбль нейронных сетей обучался на тестовом наборе из 160 синтетических элементов до достижения точности 95 % на тестовом множестве. Создание высокоточной модели в данных условиях не имеет смысла, а основные усилия были направлены на минимизацию сложности нейронных сетей, входящих в ансамбль, и на достаточно плавный характер обучения – монотонно убы-

вающая экспонента. На рис. 5 продемонстрирован характер процесса обучения нейросетевого ансамбля – обобщенные графики изменения среднеквадратических ошибок на обучающем (128 экземпляров), контрольном (32 экземпляра) и тестовом (10 экземпляров) множествах. Достаточно плавное уменьшение оши-

бок на каждом множестве свидетельствует об отсутствии эффекта переобучения нейронных сетей.

Сравнительный анализ относительных ошибок выходных значений на тестовом и обучающем множествах (табл. 3) позволяет судить о том, что нейросетевая модель приобрела высокую обобщающую способность.

Таблица 2. Пример формирования синтетического вектора

Table 2. Example of the synthetic-vector preparation

Элементы вектора Vector elements	Вектор/Vector			
	Базовый № 1 Base no. 1	Базовый № 2 Base no. 2	Расстояния Distance	Синтетический Synthetic
Компоненты бурового раствора/Drilling mud components				
Мраморная крошка/Marble chips	3,5	4,0	0,5	3,63
Полианионная целлюлоза Polyanionic cellulose	3,5	4,0	0,5	3,63
Сульфано́л/Sulfanol	1,0	1,5	0,5	1,13
Хлористый калий/Potassium chloride	1,0	1,5	0,5	1,13
Метилсилико́нат калия Potassium metasilicate	0,5	1,0	0,5	0,63
Ацетат калия/Potassium acetate	0,5	1,0	0,5	0,63
Бишофит/Bischofite	1,0	1,5	0,5	1,13
Феррохро́млиносульфат Ferrochromolignosulfonate	0,5	1,0	0,5	0,63
Гидрофобизатор/Oil wetting agent	0,5	1,0	0,5	0,63
Аллюминат калия/Potassium aluminate	3,5	4,0	0,5	3,63
Реагент СМАД/SMAD reagent	0,5	1,0	0,5	0,63
Нанодисперсная медь Nanodisperse copper	0,5	1,0	0,5	0,63
Свойства бурового раствора/Drilling mud properties				
Плотность/Density	1,25	1,26	0,0	1,25
Вязкость/Viscosity	28,0	29,0	1,0	28,25
Водоотдача/Filtration	3,0	2,5	-0,5	2,88
СНС 1 минута/Gel strength 1 min	48,0	50,0	2,0	48,50
СНС 10 минут/Gel strength 10 min	68,0	70,0	2,0	68,50
pH	10,0	10,0	0,0	10,00
Липкость/Stickability	0,1	0,1	0,0	0,10
Толщина корки/Filter cake thickness	1,5	1,5	0,0	1,50
Содержание песка/Mud sand content	1,0	1,0	0,0	1,00

Таблица 3. Выходные значения и относительные ошибки нейросетевой модели на тестовом и обучающем множествах

Table 3. Output values and percentage errors of the neural network model using the test set and the learning set

№ образца/Sample no.		1	2	3	4	5	6	7	8	9	10	$\delta_{cp}/\delta_{avg}, \%$
Свойство/Characteristic												
Плотность Density	y	1,25	1,26	1,27	1,28	1,27	1,28	1,29	1,30	1,31	1,32	5,03
	d	1,19	1,33	1,21	1,21	1,20	1,35	1,36	1,23	1,25	1,25	
	δ	4,89	5,32	4,56	5,20	5,40	5,14	5,04	5,31	4,47	4,97	
Вязкость Viscosity	y	28,0	29,0	31,0	31,0	30,0	31,0	32,0	33,0	34,0	35,0	5,42
	d	26,44	30,55	29,39	29,28	28,45	32,71	33,74	31,17	32,15	33,13	
	δ	5,56	5,36	5,20	5,55	5,17	5,51	5,45	5,56	5,45	5,35	
Водоотдача Filtration	y	3,0	2,5	1,5	1,0	1,1	1,0	0,8	0,7	0,6	0,5	5,13
	d	2,84	2,62	1,42	0,95	1,04	1,05	0,84	0,66	0,57	0,48	
	δ	5,36	4,86	5,42	5,04	5,90	5,46	4,88	5,24	4,50	4,68	
Статическое напряжение сдвига 1 мин Gel strength 1 min	y	48,0	50,0	52,0	54,0	52,0	54,0	56,0	58,0	60,0	69,0	5,66
	d	45,10	53,02	49,06	50,77	49,28	57,15	58,90	54,74	57,08	64,80	
	δ	6,05	6,04	5,65	5,99	5,24	5,84	5,17	5,62	4,87	6,09	
Статическое напряжение сдвига 10 мин Gel strength 10 min	y	68,0	70,0	78,0	80,0	78,0	80,0	86,0	88,0	90,0	93,0	5,39
	d	63,95	73,66	74,12	75,20	74,18	84,47	90,45	83,61	85,00	87,86	
	δ	5,96	5,23	4,98	6,00	4,90	5,59	5,18	4,99	5,56	5,53	
Коэффициент трения Friction coefficient	y	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	4,95
	d	0,10	0,11	0,09	0,10	0,10	0,11	0,10	0,10	0,10	0,09	
	δ	4,92	5,12	5,04	4,79	4,86	5,06	4,90	4,85	4,76	5,15	
Толщина корки Filter cake thickness	y	1,5	1,5	1,5	1,5	1,4	1,3	1,2	1,3	1,4	1,5	5,24
	d	1,43	1,58	1,42	1,41	1,33	1,36	1,26	1,23	1,32	1,42	
	δ	4,90	5,16	5,22	5,67	5,33	4,93	5,28	5,08	5,54	5,31	

y – реальное значение свойства/real value of the characteristic;
d – значение, выдаваемое нейросетевой моделью/value given by the neural network model;
 δ – относительная ошибка нейросетевой модели/relative error of the neural network model.




Рис. 5. Графики изменения ошибок при обучении нейросетевой модели высокатионно-ингибированного бурового раствора [15]

Fig. 5. Graphs of errors changing during the high-cation-inhibited drilling mud neural network model training [15]

Относительные выходные ошибки на обучающем и тестовом множествах находятся в диапазоне 4,7–5,6 %. Приобретённые обобщающие свойства нейросетевой модели позволяют предсказывать значения свойств новых наноструктурированных буровых растворов с заданной точностью для последующего прогнозирования возникновения дифференциального прихвата.

Выводы

1. Прогноз и предотвращение дифференциальных прихватов колонны буровых труб является пер-

СПИСОК ЛИТЕРАТУРЫ

1. Barnes H.A., Hutton J.F., Walters K. An introduction to rheology. – Amsterdam, The Netherlands: Elsevier, 1989. – 199 p.
2. Hole-cleaning performance comparison of oil-based and water-based drilling fluids / S. Sayindla, B. Lund, J.D. Ytrehus, A. Saasen // Journal of Petroleum Science and Engineering. – 2017. – V. 159. – P. 49–57.
3. A critical review of drilling mud rheological models / O.E. Agwu, J.U. Akpabio, M.E. Ekenyong, U.G. Inyang, D.E. Asuquo, I.J. Eyoh, O.S. Adeoye // Journal of Petroleum Science and Engineering. – 2021. – V. 203. DOI: 10.1016/j.petrol.2021.108659.
4. Alsabaa A., Elkatatny S. Improved tracking of the rheological properties of max-bridge oil-based mud using artificial neural networks // ACS OMEGA. – 2021. – V. 6 (24). – P. 15816–15826. DOI: 10.1021/acsomega.1c01230.
5. Prediction of the rheological properties of invert emulsion mud using an artificial neural network / A. Gowida, S. Khaled, S. Goma, A. Attia // ACS OMEGA. – 2021. – V. 6 (48). – P. 32948–32959. DOI: 10.1021/acsomega.1c04937.
6. Newly developed correlations to predict the rheological parameters of high-bentonite drilling fluid using neural networks / A. Gowida, S. Elkatatny, K. Abdelgawad, R. Gajbhiye // Sensors. – 2020. – V. 20 (10). DOI: 10.3390/s20102787.
7. Real-time determination of rheological properties of spud drilling fluids using a hybrid artificial intelligence technique / K. Abdelgawad, S. Elkatatny, T. Moussa, M. Mahmoud, S. Patil // Journal of Energy Resources Technology. – 2019. – V. 141. DOI: 10.1115/1.4042233.

спективной и актуальной задачей, для эффективного решения которой необходимо использовать предложенный авторами высокоингибированный наноструктурированный буровой раствор.

2. Частично варьируемый состав нового раствора обладает высочайшей ингибирующей способностью, что обеспечивает замедление процесса гидратации и набухания глинистых отложений и ведет к существенному уменьшению вероятности возникновения дифференциального прихвата.
3. Применение разработанного раствора позволяет успешно сооружать разведочные скважины на нефть и газ глубиной более 3000 м с горизонтальным окончанием на участках, представленных неустойчивыми высокопластичными глинами.
4. В работе оценено реологическое поведение предлагаемого раствора с улучшенными структурно-реологическими, фильтрационными и фрикционными свойствами на базе двухуровневой нейросетевой ансамблевой модели.
5. Модель, построенная на базе многослойных перцептронов, отражает существенно нелинейные взаимосвязи между компонентным составом и основными свойствами бурового раствора.
6. Прогнозируемые реологические параметры могут использоваться как для оперативного внесения изменений в процесс бурения, так и для последующего прогноза и определения вероятности возникновения дифференциального прихвата.
7. Развитие и совершенствование предложенной нейросетевой реологической модели может идти по пути учета конкретных геологических условий и технологических параметров бурения, применяющихся в качестве входных данных модели.
8. Elkatatny S.M. Determination the rheological properties of invert emulsion based mud on real time using artificial neural network // Proceedings of the SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition/ – Dammam, Saudi Arabia, 25–28 April 2016. – Paper No. SPE-182801-MS. DOI: 10.2118/182801-MS.
9. Elkatatny S.M. Real-time prediction of rheological parameters of KCl water-based drilling fluid using artificial neural networks // Arabian Journal of Science and Engineering. – 2017. – V. 42. – P. 1655–1665. DOI: 10.1007/s13369-016-2409-7.
10. Data-driven framework to predict the rheological properties of CaCl₂ brine-based drill-in fluid using artificial neural network / A. Gowida, S.M. Elkatatny, E. Ramadan, A. Abdulraheem // Energies. – 2019. – V. 12. – № 10:1880. DOI: 10.3390/en12101880.
11. Elkatatny S. Real-time prediction of the rheological properties of water-based drill-in fluid using artificial neural networks // Sustainability. – 2019. – V. 11. – № 18:5008. DOI: 10.3390/su11185008.
12. Elahifar B., Hosseini E. Machine learning algorithm for prediction of stuck pipe incidents using statistical data: case study in middle east oil fields // Journal of Petroleum Exploration and Production Technology. – 2022. – V. 12. – P. 2019–2045. DOI: 10.1007/s13202-021-01436-3.
13. Characterization based machine learning modeling for the prediction of the rheological properties of water-based drilling mud: an experimental study on grass as an environmental friendly additive / A. Ismail, H.M.A. Rashid, R. Gholami, A. Raza // Journal of Petroleum Exploration and Production Technology. – 2022. – V. 12. – P. 1677–1695. DOI: 10.1007/s13202-021-01425-6.

14. Adams N.J., Charrier T. Drilling engineering: a complete well planning approach. – Tulsa, OK, USA: Penn Well Publishing Company, 1985. – 960 p.
15. Высококативно-ингибированный буровой раствор: пат. Рос. Федерация, № 2768340, заявл. 24.05.2021; опубл. 23.03.2022, Бюл. № 9.
16. Высокоингибированный инвертный буровой раствор: пат. Рос. Федерация, № 2710654, заявл. 03.04.2019; опубл. 30.12.2019, Бюл. № 36.
17. Высокоингибированный буровой раствор: пат. Рос. Федерация, № 2303047, заявл. 10.05.2006; опубл. 20.07.2007, Бюл. № 19.
18. Буровой раствор: патент Рос. Федерация, № 2582197C1, заявл. 25.03.2015 опубл. 20.04.2020, Бюл. № 13.
19. Наноструктурированный высокоингибированный буровой раствор: пат. Рос. Федерация, № 2708849C1, заявл. 24.01.2019; опубл. 12.12.2007, Бюл. № 35.
20. Эмульсионно-ингибированный реверсивно-инвертный буровой раствор пат. Рос. Федерация, № 2768357C1, заявл. 24.05.2021 опубл. 23.03.2022, Бюл. № 9.
21. Hartono P., Hashimoto S. Learning with ensemble of linear perceptrons // International Conference on Artificial Neural Networks: Formal Models and Their Applications – ICANN 2005. – Berlin, Heidelberg: Springer, 2005. – V. 3697. – P. 115–120. DOI: 10.1007/11550907_19.
22. Андронов Ю.В., Стрекалов А.В. Исследование применения ансамблей нейронных сетей для повышения качества решения задач регрессии // Нефтегазовое дело. – 2015. – № 1. – С. 50–55.
23. Третьяк А.Я., Кузнецова А.В., Борисов К.А. Определение параметров резцов с помощью регрессивного и нейросетевого моделирования. // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2019. – Т. 330. – № 5. – С. 169–177.
24. Опыт применения искусственных нейронных сетей для прогнозирования оптимальных параметров режима бурения скважин / Г.В. Буслаев, М.М. Павлов, А.А. Куншин, В.В. Стариков, Г.М. Сергеев // Научный журнал Российского газового общества. – 2019. – № 2 (21). – С. 51–55.
25. Кодиров Ш.Ш., Шестаков А.Л. Разработка искусственной нейронной сети для прогнозирования прихватов колонн буровых труб // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». – 2019. – Т. 19. – № 3. – С. 20–32. DOI: 10.14529/ctcr190302.
26. Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6. – М.: ДИАЛОГ-МИФИ, 2001. – 630 с.
27. Harrell F.E. Regression modeling strategies: with applications to linear models, logistic regression, and survival analysis. – New York: Springer-Verlag, 2001. DOI: 10.1007/978-1-4757-3462-1.
28. Chawla N.V., Bowyer K.W., Hall L.O. SMOTE: Synthetic Minority Oversampling Technique // J. Artificial Intelligence Research. – 2002. – V. 16. – P. 321–357. DOI: 10.1613/jair.953.

Поступила 06.07.2022 г.

Информация об авторах

Третьяк А.Я., доктор технических наук, профессор, заведующий кафедрой нефтегазовых техники и технологий Южно-Российского государственного политехнического университета (НПИ) им. М.И. Платова.

Кузнецова А.В., кандидат технических наук, доцент кафедры программного обеспечения вычислительной техники Южно-Российского государственного политехнического университета (НПИ) им. М.И. Платова.

Борисов К.А., кандидат технических наук, доцент кафедры нефтегазовых техники и технологий Южно-Российского государственного политехнического университета (НПИ) им. М.И. Платова.

Карельская Е.В., ассистент кафедры нефтегазовых техники и технологий Южно-Российского государственного политехнического университета (НПИ) им. М.И. Платова.

UDC 004.8.622.24

NEURAL NETWORK FORECASTING OF DRILLING MUD RHEOLOGICAL PARAMETERS

Alexander Ya. Tretyak¹,
13050465@mail.ru

Alla V. Kuznetsova¹,
alvitkuz@yandex.ru

Konstantin A. Borisov¹,
13020165@mail.ru

Ekaterina V. Karelskaya¹,
karelskaya_1992@mail.ru

¹ M.I. Platov South-Russian State Polytechnic University (NPI),
132, Prosveshcheniya street, Novocherkassk, 346428, Russia.

The relevance of the study is caused by the fact that differential tacks are one of the most difficult accidents in the entire technological chain of construction of oil and gas wells. A high quality and correctly selected drilling mud with optimal rheology for specific drilling conditions is one of the determining factors in preventing differential tacks.

Goal: development of a neural network rheological model of drilling mud based on its component composition and the results of periodic measurements of the output parameters of the flushing fluid. With the help of a neural network, it is possible to accurately and quickly predict the values of the rheological properties of the solution, which have a significant impact on the occurrence and prevention of differential seizures.

Object: neural network rheological models of drilling mud, drilling muds, which composition affects the rheological properties and the possibility of preventing differential sticking of the drill string during well construction.

Methods: neural network model of drilling mud differing in the number and composition of input parameters is proposed.

Results. The paper describes the learning process of three neural networks based on operational data obtained on instruments for measuring drilling mud parameters. The authors proposed six types of drilling muds that are optimal for specific geological conditions. Introduction of nanodispersed copper and potassium aluminate into the composition of a drilling mud with a high lubricity helps to reduce the friction coefficient, increase the inhibitory ability of the solution, reduce water loss and, as a result, decrease sharply the differential tack during the construction of wells on hydrocarbon raw materials.

Key words:

Differential tack of a drill pipe column, forecast of tacks, drilling nanostructured mud, artificial neural networks, neural network model of drilling mud.

REFERENCES

1. Barnes H.A., Hutton J.F., Walters K. *An introduction to rheology*. Amsterdam, The Netherlands, Elsevier, 1989. 199 p.
2. Sayindla S., Lund B., Ytrehus J.D., Saasen A. Hole-cleaning performance comparison of oil-based and water-based drilling fluids. *Journal of Petroleum Science and Engineering*, 2017, vol. 159, pp. 49–57.
3. Agwu O.E., Akpabio J.U., Ekpenyong M.E., Inyang U.G., Asuquo D.E., Eyoh I.J., Adeoye O.S. A critical review of drilling mud rheological models. *Journal of Petroleum Science and Engineering*, 2021, vol. 203. DOI: 10.1016/j.petrol.2021.108659.
4. Alsabaa A., Elkatatny S. Improved tracking of the rheological properties of max-bridge oil-based mud using artificial neural networks. *ACS OMEGA*, 2021, vol. 6 (24), pp. 15816–15826. DOI: 10.1021/acsomega.1c01230.
5. Gowida A., Khaled S., Gomaa S., Attia A. Prediction of the rheological properties of invert emulsion mud using an artificial neural network. *ACS OMEGA*, 2021, vol. 6 (48), pp. 32948–32959. DOI: 10.1021/acsomega.1c04937.
6. Gowida A., Elkatatny S., Abdelgawad K., Gajbhiye R. Newly developed correlations to predict the rheological parameters of high-bentonite drilling fluid using neural networks. *Sensors*, 2020, vol. 20 (10). DOI: 10.3390/s20102787.
7. Abdelgawad K., Elkatatny S., Moussa T., Mahmoud M., Patil S. Real-time determination of rheological properties of spud drilling fluids using a hybrid artificial intelligence technique. *Journal of Energy Resources Technology*, 2019, vol. 141. DOI: 10.1115/1.4042233.
8. Elkatatny S.M. Determination the rheological properties of invert emulsion based mud on real time using artificial neural network. *Proceedings of the SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition*. Dammam, Saudi Arabia, 25–28 April 2016. DOI: 10.2118/182801-MS.
9. Elkatatny S.M. Real-time prediction of rheological parameters of KCl water-based drilling fluid using artificial neural networks. *Arabian Journal of Science and Engineering*, 2017, vol. 42, pp. 1655–1665. DOI: 10.1007/s13369-016-2409-7.
10. Gowida A., Elkatatny S.M., Ramadan E., Abdurraheem A. Data-driven framework to predict the rheological properties of CaCl₂ brine-based drill-in fluid using artificial neural network. *Energies*, 2019, vol. 12, no. 10:1880. DOI: 10.3390/en12101880.
11. Elkatatny S. Real-time prediction of the rheological properties of water-based drill-in fluid using artificial neural networks. *Sustainability*, 2019, vol. 11, no. 18:5008. DOI: 10.3390/su11185008.
12. Elahifar B., Hosseini E. Machine learning algorithm for prediction of stuck pipe incidents using statistical data: case study in middle east oil fields. *Journal of Petroleum Exploration and Production Technology*, 2022, vol. 12, pp. 2019–2045. DOI: 10.1007/s13202-021-01436-3.
13. Ismail A., Rashid, H.M.A., Gholami R., Raza A. Characterization based machine learning modeling for the prediction of the rheological properties of water-based drilling mud: an experimental study on grass as an environmental friendly additive. *Journal of Petroleum Exploration and Production Technology*, 2022, vol. 12, pp. 1677–1695. DOI: 10.1007/s13202-021-01425-6.
14. Adams N.J., Charrier T. *Drilling engineering: a complete well planning approach*. Tulsa, OK, USA, Penn Well Publishing Company, 1985. 960 p.
15. Tretyak A.Ya., Karelskaya E.V., Krymov A.V., Onofrienko S.A. *Vysokokationno-ingibirovanny burovoy rastvor* [Highly cationic inhibited drilling mud]. Patent RF, no. 2768340, 2022.

16. Tretyak A.A., Onofrienko S.A. *Vysokoingibirovanny invertny burovoy rastvor* [Highly inhibited invert drilling mud]. Patent RF, no. 2710654, 2019.
17. Tretyak A.Ya., Zaretsky V.S., Mnatsakanov V.A., Rybalchenko Yu.M., Frolov P.A., Chikhotkin V.F., Shamanov S.A. *Vysokoingibirovanny burovoy rastvor* [Highly inhibited drilling mud]. Patent RF, no. 2303047, 2007.
18. Tretyak A.A., Rybalchenko Yu.M., Shvets V.V., S.I. Lubyanova, Turuntaev Yu.Yu., Borisov K.A. *Burovoy rastvor* [Drilling mud]. Patent RF, no. 2582197, 2020.
19. Tretyak A.A., Onofrienko S.A. *Nanostrukturirovanny vysokoingibirovanny burovoy rastvor* [Nanostructured highly inhibited drilling mud]. Patent RF, no. 2708849C1, 2007.
20. Tretyak A.A., Karelskaya E.V., Lizogub A.A., Sidorova E.V. *Emulsionno-ingibirovanny reversivno-invertny burovoy rastvor* [Emulsion-inhibited reverse-invert drilling mud]. Patent RF, no. 2768357C1, 2022.
21. Hartono P., Hashimoto S. Learning with Ensemble of Linear Perceptrons. *International Conference on Artificial Neural Networks: Formal Models and Their Applications – ICANN 2005*. Berlin, Heidelberg, Springer, 2005. Vol. 3697, pp. 115–120. DOI: 10.1007/11550907_19.
22. Andronov Yu.V., Strekalov A.V. Research on the use of ensembles of neural networks to improve the quality of solving regression problems. *Petroleum Engineering*, 2015, vol. 13, no. 1, pp. 50–55. In Rus.
23. Tretyak A.Ya., Kuznetsova A.V., Borisov K.A. Determination of cutter breakages using regression and neural network modeling. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2019, vol. 330, no. 5, pp. 169–177. In Rus.
24. Buslyayev G.V., Pavlov M.M., Kunshin A.A. Experience in the use of artificial neural networks to predict the optimal parameters of the well drilling regime. *Scientific journal of the Russian Gas Society*, 2019, vol. 2 (21), pp. 51–55. In Rus.
25. Kodirov Sh.Sh., Shestakov A.L. Development of an artificial neural network for predicting sticking of drill strings. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*, 2019, vol. 19, no. 3, pp. 20–32. In Rus.
26. Medvedev V.S., Potemkin V.G. *Neyronnye seti. MATLAB 6* [Neural networks. MATLAB 6]. Moscow, DIALOG-MEPHI, 2001. 630 p.
27. Harrell F.E. *Regression modeling strategies: with applications to linear models, logistic regression, and survival analysis*. New York, Springer-Verlag, 2001. DOI: 10.1007/978-1-4757-3462-1.
28. Chawla N.V., Bowyer K.W., Hall L.O. SMOTE: Synthetic Minority Oversampling Technique. *Journal Artificial Intelligence Research*, 2002, vol. 16, pp. 321–357. DOI: 10.1613/jair.953.

Received: 6 July 2022.

Information about the authors

Alexander Y. Tretyak, Dr. Sc., professor, head of the department of Oil and Gas Engineering and Technologies, M.I. Platov South Russian State Polytechnic University (NPI).

Alla V. Kuznetsova, Cand. Sc., associate professor, M.I. Platov South-Russian State Polytechnic University (NPI) of the department of Computer Engineering Software.

Konstantin A. Borisov, Cand. Sc., associate professor, M.I. Platov South-Russian State Polytechnic University (NPI) of the department of Oil and Gas Engineering and Technologies.

Ekaterina V. Karelskaya, assistant, M.I. Platov South-Russian State Polytechnic University (NPI).