



ПРЕДЕЛЬНАЯ
ПРОТЯЖЕННОСТЬ
ERD-СКВАЖИНЫ

● КИСЛОТНОСТРУЙНОЕ
БУРЕНИЕ

● ЛОВИЛЬНЫЕ МЕТЧИКИ
ДЛЯ СКВАЖИННЫХ
РАБОТ

Нефтегаз.RU

ДЕЛОВОЙ ЖУРНАЛ

ИНТЕРЕСНО О СЕРЬЕЗНОМ

ISSN 2410-3837

7 [176] 2026

ПОВЫШЕНИЕ
ЭФФЕКТИВНОСТИ
БУРЕНИЯ
С ИСПОЛЬЗОВАНИЕМ
РАСШИРЕННОЙ
АНАЛИТИКИ
ДАННЫХ



Входит в перечень ВАК (K1)

КАЧЕСТВО СТРОИТЕЛЬСТВА СКВАЖИН: модель оценки на основе нейронных сетей

В СТАТЬЕ ПРЕДСТАВЛЕН ПОДХОД К ОЦЕНКЕ КАЧЕСТВА СТРОИТЕЛЬСТВА НЕФТЯНЫХ И ГАЗОВЫХ СКВАЖИН НА ОСНОВЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ. ВЫПОЛНЕН СРАВНИТЕЛЬНЫЙ АНАЛИЗ ТРАДИЦИОННОЙ КВАЛИМЕТРИЧЕСКОЙ МОДЕЛИ И МОДЕЛИ, ПОСТРОЕННОЙ С ИСПОЛЬЗОВАНИЕМ МНОГОСЛОЙНОГО ПЕРСЕПТРОНА. ПОКАЗАНО, ЧТО КЛАССИЧЕСКИЕ МЕТОДЫ ОБЛАДАЮТ РЯДОМ ОГРАНИЧЕНИЙ И НЕДОСТАТОЧНЫМ УЧЕТОМ ВЗАИМОСВЯЗЕЙ МЕЖДУ ПАРАМЕТРАМИ КАЧЕСТВА. ПРЕДЛОЖЕНА АРХИТЕКТУРА НЕЙРОННОЙ СЕТИ В ВИДЕ МНОГОСЛОЙНОГО ПЕРСЕПТРОНА ДЛЯ РАСЧЕТА КОМПЛЕКСНОГО ПОКАЗАТЕЛЯ КАЧЕСТВА СТРОИТЕЛЬСТВА СКВАЖИН НА ОСНОВЕ СОВОКУПНОСТИ КОЛИЧЕСТВЕННЫХ ПАРАМЕТРОВ. ПОДРОБНО РАССМОТРЕНЫ ПРИНЦИПЫ ФУНКЦИОНИРОВАНИЯ СЕТИ. ОБОСНОВАНЫ ПРЕИМУЩЕСТВА НЕЙРОСЕТЕВОГО ПОДХОДА ПРИ ОБРАБОТКЕ СЛОЖНЫХ НЕЛИНЕЙНЫХ ЗАВИСИМОСТЕЙ, ЗАШУМЛЕННЫХ ДАННЫХ И ЭКСПЕРТНЫХ ОЦЕНОК. ОТМЕЧЕНО, ЧТО ПРИМЕНЕНИЕ МЕТОДОВ ИИ ПОЗВОЛЯЕТ ПОВЫСИТЬ ОБЪЕКТИВНОСТЬ, АДАПТИВНОСТЬ И ТОЧНОСТЬ ОЦЕНКИ. УКАЗАНЫ ОГРАНИЧЕНИЯ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ, СВЯЗАННЫЕ С НЕОБХОДИМОСТЬЮ НАЛИЧИЯ ОБУЧАЮЩИХ ВЫБОРОК И СЛОЖНОСТЬЮ ИНТЕРПРЕТАЦИИ РЕЗУЛЬТАТОВ. СДЕЛАН ВЫВОД О ПЕРСПЕКТИВНОСТИ ИНТЕГРАЦИИ МЕТОДОВ КВАЛИМЕТРИИ И ИИ ДЛЯ РАЗВИТИЯ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ УПРАВЛЕНИЯ КАЧЕСТВОМ В НГК

THE ARTICLE PRESENTS AN APPROACH TO ASSESSING THE QUALITY OF OIL AND GAS WELL CONSTRUCTION BASED ON NEURAL NETWORK TECHNOLOGIES. A COMPARATIVE ANALYSIS OF A TRADITIONAL QUALIMETRIC MODEL AND A MODEL DEVELOPED USING A MULTILAYER PERCEPTRON WAS CARRIED OUT. IT IS DEMONSTRATED THAT CLASSICAL QUALIMETRIC METHODS POSSESS SEVERAL LIMITATIONS ASSOCIATED WITH THE LINEAR NATURE OF INDICATOR AGGREGATION AND THE INSUFFICIENT CONSIDERATION OF INTERRELATIONSHIPS AMONG QUALITY PARAMETERS. AN ARCHITECTURE OF A MULTILAYER PERCEPTRON NEURAL NETWORK IS PROPOSED FOR CALCULATING AN INTEGRATED INDICATOR OF WELL CONSTRUCTION QUALITY BASED ON A SET OF QUANTITATIVE PARAMETERS. THE PRINCIPLES OF NETWORK OPERATION ARE EXAMINED IN DETAIL, INCLUDING THE NEURON ACTIVATION MECHANISM, THE APPLICATION OF LOSS FUNCTIONS, AND THE USE OF BACKPROPAGATION AND GRADIENT DESCENT ALGORITHMS. THE ADVANTAGES OF THE NEURAL NETWORK APPROACH IN PROCESSING COMPLEX NONLINEAR DEPENDENCIES, NOISY DATA, AND EXPERT ASSESSMENTS ARE SUBSTANTIATED. IT IS NOTED THAT THE APPLICATION OF ARTIFICIAL INTELLIGENCE METHODS ENHANCES THE OBJECTIVITY, ADAPTABILITY, AND ACCURACY OF WELL CONSTRUCTION QUALITY ASSESSMENT. AT THE SAME TIME, THE LIMITATIONS OF NEURAL NETWORK MODELS ARE IDENTIFIED, PARTICULARLY THE REQUIREMENT FOR TRAINING DATASETS AND THE COMPLEXITY OF RESULT INTERPRETATION. THE STUDY CONCLUDES THAT THE INTEGRATION OF QUALIMETRIC METHODS AND ARTIFICIAL INTELLIGENCE IS A PROMISING DIRECTION FOR THE DEVELOPMENT OF INTELLIGENT QUALITY MANAGEMENT SYSTEMS IN THE OIL AND GAS INDUSTRY.

Ключевые слова: строительство скважин, качество бурения, оценка качества, квалиметрия, нейросеть, многослойный персептрон.

Ахмадуллин
Андрей Эдуардович
специалист

Ахмадуллин
Александр Эдуардович
специалист


ООО «Прикладные научно-
технические проекты»

По данным «Яндекса» и консалтинговой компании «Яков и Партнеры», к 2030 году суммарный годовой экономический эффект для российской экономики от внедрения технологий искусственного интеллекта (ИИ) составит 7,9–12,8 трлн рублей, что эквивалентно 5,5% от прогнозируемого ВВП России в 2030 году [1]. Несмотря на то что в настоящее время отечественная экосистема ИИ вступила в фазу масштабирования, средние инвестиции российских компаний

ТЭК в технологии ИИ за 2025 год составляют всего 14% от годового бюджета на информационные технологии [1]. В этом отношении отечественные компании уступают нефтяным компаниям США и Западной Европы, которые активно внедряют в производство технологии ИИ, в том числе в области мониторинга, контроля и управления строительством скважин. Спектр решаемых за рубежом с помощью искусственного интеллекта задач достаточно

УДК 622.24:004.89

РИСУНОК 1. Дерево критериев строительства скважины (один из возможных вариантов)



широк: от раннего обнаружения газонефтеводопроявлений и оптимизации режимов бурения до принятия управленческих решений, направленных на снижение непроизводительного времени (НПВ), аварийности и операционных затрат [2, 3].

Одно из перспективных направлений применения ИИ в бурении – использование нейронных сетей для оценки качества строительства скважин. Применение аналитических систем нового поколения в этой области позволяет не только создать прочный фундамент для управления качеством сервисного производства, но и существенно повысить эффективность буровых работ.

Постановка задачи оценки качества

Построение любой модели оценки качества начинается с детерминации граничных условий [4]. Для строительства скважин определяется предмет оценки (например, производственный процесс буровых работ или скважина как конечный продукт строительства). Определяется способ оценки качества (например, посредством сопоставления технических решений, заложенных в проектную документацию, и фактически достигнутых результатов). Определяются категории скважин,

подлежащих оценке (например, добывающие и/или нагнетательные, построенные на суше и/или на шельфе) [5].

Затем для выбранной категории скважин строится модель качества в виде иерархического дерева, где качество декомпозируется до ключевых критериев. Такое иерархическое дерево (рис. 1) позволяет выйти на последнем ярусе (т.е. уровне дерева с наибольшим количеством ветвей) на ключевые критерии оценки [5].

Для всех критериев определяются количественно измеряемые фактические и проектные параметры, например, такие как:

- Отклонение ствола скважины от центра круга допуска, м.
- Максимальная интенсивность искривления ствола скважины, град/10 м.
- Механическая скорость проходки, м/ч.
- Плотность бурового раствора, г/см³.
- Падение давления опрессовки обсадной колонны за 30 мин, МПа.
- Протяженность интервалов сплошного контакта цемента с горной породой, м.
- Протяженность интервалов сплошного контакта цемента с обсадной колонной, м.
- Высота подъема цемента за обсадными колоннами, м.
- Дебит добывающей скважины после освоения, м³/сут.

- Приемистость нагнетательной скважины после освоения, м³/сут.
- НПВ, сут.
- Величина загрязнения окружающей среды нефтью, нефтепродуктами, т.

Перечисленные параметры приведены для иллюстрации и не являются исчерпывающими. Предположим, что при помощи дерева критериев определено 40 параметров, характеризующих качество строительства скважины:

$$X = \{x_1, x_2, \dots, x_n, \dots, x_{40}\}$$

Задача в такой постановке сводится к нахождению комплексного показателя качества (K), являющегося функцией параметров строительства скважины (X):

$$K = f(X) \quad (1)$$

где K – комплексный показатель качества строительства скважины, $K \in [0; 100]$; f – некая функция.

Рассмотрим далее, как сформулированная задача решается в рамках квалиметрии и в рамках модели оценки качества с использованием нейронных сетей.

Квалиметрическая оценка

Непосредственно оперировать (складывать и агрегировать) параметрами строительства скважины не представляется возможным, поскольку они имеют несопоставимую друг с другом

размерность (м, град/10 м, м/ч, г/см³, МПа, сут, м³/сут, т). Для того чтобы производить над ними математические преобразования, в квалиметрии все параметры (x_i) переводятся в относительный, т.е. безразмерный вид (k_i):

$$\begin{aligned} x_1 &\rightarrow k_1, \\ x_2 &\rightarrow k_2, \\ &\dots \\ x_n &\rightarrow k_n, \\ &\dots \\ x_{40} &\rightarrow k_{40} \end{aligned}$$

так чтобы $k_i \in [0; 100]$, где i – порядковый номер параметра и его относительного безразмерного показателя. Для такого перевода применяется классическая формула нормирования [6, 7]:

$$k_i = \frac{x_i - x_i^{\text{бр}}}{x_i^{\text{эт}} - x_i^{\text{бр}}}$$

где k_i – относительный показатель параметра в безразмерном виде;

x_i – параметр, измеряемый в абсолютных (размерных) единицах; $x_i^{\text{эт}}$ – эталонное (наилучшее) значение параметра;

$x_i^{\text{бр}}$ – браковочное (неприемлемое) значение параметра.

Способы нахождения эталонных и браковочных значений параметров для строительства скважин подробно изложены в монографии [5]. С учетом выполненных преобразований *комплексный показатель качества* находится на основе средних взвешенных арифметических, геометрических или гармонических величин [4]. Большинство исследователей отдает предпочтение средней взвешенной арифметической оценке благодаря простоте вычисления, а также тому обстоятельству, что ее результат в равной степени зависит от всех осредняемых величин [4, 5]. Для 40 параметров бурения комплексный показатель качества (K) вычисляется как средняя взвешенная арифметическая:

$$K = \sum_{i=1}^{40} g_i k_i \quad (\text{III})$$

где k_i – относительный (безразмерный) показатель i -го параметра,

g_i – вес i -го относительного показателя, выбранный экспертным, аналитическим или комбинированным методом [5, 6] так, чтобы

$$\sum_{i=1}^{40} g_i = 1.$$

Из формулы (II) следуют два главных недостатка квалиметрической оценки качества:

- Модель предполагает строгую линейную зависимость комплексного показателя от относительных показателей;
- Модель не учитывает взаимное влияние относительных показателей (параметров) друг на друга.

Здесь уместно вспомнить слова основоположника квалиметрии Азгальдова Г.Г.: «Комплексная оценка – не произвольное соединение оценок отдельных свойств. Вероятно, вполне правомерно рассматривать качество как систему. А если это так, то можно ли считать, например, что среднеарифметическая (или другие средние) адекватно отражает реальные связи между свойствами? Представляется, что нет. Средняя арифметическая (как и другие средние) предполагает отсутствие корреляции между отдельными свойствами или такую малую корреляцию, что ею можно пренебречь. Однако на самом деле многие свойства (если не большинство) взаимосвязаны. Разумеется, из этого не следует вывод о нежелательности

применения средних величин. Но нужно понимать, что *модели, основанные на использовании средних, являются достаточно грубыми и не снимают необходимости в разработке более точных и достоверных моделей*» [4]. Эти слова были написаны полвека назад, когда еще не существовало современных технологий ИИ, и отсутствовала возможность предложить альтернативу использованию средних величин.

Оценка качества на основе нейросети


С целью исключения отмеченных недостатков, т.е. для нахождения комплексного показателя качества (K) по нелинейной функциональной зависимости, заменим $f(X)$ в формуле (I) нейронной сетью. Для этого используем *многослойный персептрон MLP* (Multilayer Perceptron) с тремя скрытыми слоями следующей архитектуры (рис. 2):

$$40 - 128 - 64 - 16 - 1,$$

где 40 – число входных параметров, характеризующих качество строительства скважины, $\{x_1, x_2, \dots, x_n, \dots, x_{40}\}$;

128 – число нейронов в первом скрытом слое;

РИСУНОК 2. Многослойный персептрон для оценки качества строительства скважины



64 – число нейронов во втором скрытом слое;

16 – число нейронов в третьем скрытом слое;

1 – число нейронов в выходном слое, соответствующее искомому комплексному показателю качества.

Выбор архитектуры осуществлен эвристически с учетом количества входных параметров и необходимости моделирования нелинейных зависимостей при прогнозировании качества строительства скважин. Отметим, что предлагаемая архитектура (число скрытых слоев и нейронов) не является универсальной и может корректироваться в зависимости от объема обучающих данных и сложности моделируемых зависимостей.

На вход сети подается вектор признаков, характеризующих строительство скважины, $X = \{x_1, x_2, \dots, x_n, \dots, x_{40}\}$, а выходом является прогнозируемый сетью комплексный показатель качества.

В каждом нейроне скрытого слоя вычисляется взвешенная сумма входных сигналов:

$$z = \sum w_i x_i + b,$$

где x_i – входной i -й параметр;

w_i – вес i -го параметра;

b – смещение.

Полученное значение z пропускается через функцию активации:

$$a = \sigma(z),$$

где z – «сырой» результат нейрона;

σ – функция активации;

a – выход нейрона.

Функция активации – это нелинейное преобразование, которое нейрон применяет к результату своих вычислений. Без функции активации нейросеть была бы просто набором линейных преобразований, и результат, выдаваемый на ее выходе, мало отличался бы от вычислений по формуле (II). Функция активации играет ключевую роль в способности нейронной сети моделировать сложные нелинейные зависимости между параметрами качества строительства скважин и итоговым качеством.

Наиболее популярная функция активации – выпрямленная линейная единица ReLU (Rectified Linear Unit):

$$\sigma(z) = \begin{cases} z, & \text{если } z > 0 \\ 0, & \text{если } z \leq 0 \end{cases}$$

Данная функция отличается простотой вычислений, способствует ускоренному обучению сети и хорошо работает в глубоких сетях. В силу этого функция ReLU стала стандартом не только в компьютерном зрении и промышленном ИИ, но и при решении различных задач в нефтегазовом комплексе. По своему физическому смыслу функция активации ReLU похожа на датчик, срабатывающий при достижении порогового значения: если сигнал слабый, он обнуляется; если сигнал сильный, он пропускается.

Приведем *полную модель сети* в виде математических формул, сначала для выхода каждого слоя, а затем для итогового выхода:

• Выход первого скрытого слоя: $H_1 = \sigma(W_1 X + b_1)$.

• Выход второго скрытого слоя: $H_2 = \sigma(W_2 H_1 + b_2)$.

• Выход третьего скрытого слоя: $H_3 = \sigma(W_3 H_2 + b_3)$.

• Итоговый выход – комплексный показатель качества: $K = W_4 H_3 + b_4$ или, объединив формулы для трех скрытых слоев: $K = W_4 \sigma(W_3 \sigma(W_2 \sigma(W_1 X + b_1) + b_2) + b_3) + b_4$ (III)

где W_i – матрицы весов i -го слоя,

b_i – векторы смещений i -го слоя,

σ – функция активации,

X – входной вектор

признаков – набор параметров,

характеризующих качество

строительства скважины.

Процесс *обучения нейросети* производится на основе исторических данных, содержащих m примеров скважин, где для каждого j -го примера известны:

- Вектор входных параметров, характеризующих качество строительства скважины, $X^{(j)}$;
- Соответствующая экспертная оценка – комплексный показатель качества, $K^{(j)}$.

Источник данных $X^{(j)}$ – первичная промысловая информация, в том числе электронное дело скважины, суточные буровые сводки, типовые отчеты станции геолого-технической информации, результаты геофизических исследований, итоговые отчеты супервайзеров,

замеры фактических параметров технологических процессов бурения, крепления и освоения скважины, а также проектная документация.

Объем данных – несколько тысяч скважин, что сопоставимо с эксплуатационным фондом крупных нефтяных компаний России. Данные разделяют на три группы:

- Обучающая выборка (Training Set), объем которой, как правило, составляет 70 – 80%.
- Валидационная выборка (Validation Set) – 10 – 15%.
- Тестовая выборка (Test Set) – 10 – 15%.

На первой – самой большой – выборке производится обучение сети, что следует из ее названия. Две последние необходимы для финальной настройки модели и проверки ее способности к правильному прогнозу качества (для обучения они не используются).

Если у недропользователя небольшой пробуренный фонд, рекомендуется использовать данные по скважинам аналогичной конструкции (по количеству, типоразмерам и глубинам спуска обсадных колонн), пробуренных в схожих горно-геологических условиях.

Формирование экспертных оценок $K^{(j)}$ осуществляется на основе научно-методических положений квалиметрии [5].


Задача обучения сети заключается в том, чтобы значение комплексного показателя качества, предсказанное сетью по формуле (III), было близко к экспертной оценке (к истинному значению):

$$K_{pred}^{(j)} \approx K_{true}^{(j)}.$$

Так как сама нейросеть не знает, хорошие у нее веса или плохие, правильно ли она предсказывает или нет, ей необходим инструмент, дающий представление о «цене ошибки». Таким инструментом является функция потерь (Loss Function), показывающая, насколько предсказание сети отличается от правильного ответа (экспертной оценки). Главная цель обучения нейронной сети – это как раз минимизация функции потерь, т.е. минимизация ошибки прогноза качества.

Самая распространенная функция потерь – среднеквадратичная ошибка MSE (Mean Squared Error):

РИСУНОК 3. Принципиальная блок-схема обучения нейросети



$$L = \frac{1}{m} \sum_{j=1}^m (K_{pred}^{(j)} - K_{true}^{(j)})^2$$

где L – функция потерь;

m – число примеров в обучающей выборке ($X^{(j)}$, K_j);

$K_{pred}^{(j)}$ – значение комплексного показателя качества, предсказанное сетью;

$K_{true}^{(j)}$ – истинное значение комплексного показателя качества (экспертная оценка);

$(\dots)^2$ – квадрат ошибки.

Ошибка возводится в квадрат, чтобы большие ошибки штрафвались сильнее, а отрицательные ошибки не компенсировали положительные. Чем меньше среднеквадратичная ошибка, тем лучше работает прогноз сети. В идеальном случае значение функции потерь должно равняться нулю, что свидетельствовало бы о безошибочности предсказаний сети.

После вычисления потерь запускаются два механизма уменьшения ошибки – алгоритмы обратного распространения ошибки (Backpropagation) и градиентного спуска (Gradient Descent), применяемые в рамках единого итерационного процесса оптимизации.

Если в квалиметрической формуле (II) присутствует всего 40 весов, то в многослойном персептроне архитектуры 40–128–64–16–1 число обучаемых параметров составляет 14 561, включая 14 352 весов и 209 смещений. Данное число получено суммированием всех элементов весовых матриц и смещений:

- Матрица весов W_1 между входным и первым скрытым слоем имеет размер $128 \times 40 = 5120$;
- Матрица весов W_2 между первым и вторым скрытым слоем имеет размер $64 \times 128 = 8192$;
- Матрица весов W_3 между вторым и третьим скрытым слоем имеет размер $16 \times 64 = 1024$;
- Матрица весов W_4 между третьим скрытым слоем и выходом имеет размер $1 \times 16 = 16$;
- Суммарное число смещений первого, второго и третьего скрытых слоев, а также выходного слоя: $128 + 64 + 16 + 1 = 209$.

В процессе обучения нейросети помимо 14 352 весов (w_i) оптимизируются также 209 смещений (b_i), однако для упрощения дальнейшего изложения будем рассматривать только веса. Из 14 352 весов нейросети необходимо определить, какой именно вес и в какой степени влияет на итоговую ошибку

модели. Это осуществляется с помощью алгоритма обратного распространения ошибки. Основным инструментом алгоритма обратного распространения ошибки является вычисление частных производных функции потерь (L) по каждому весу:

$$\frac{\partial L}{\partial w_i}$$

Данная частная производная показывает, насколько изменение конкретного веса (w_i) изменяет значение функции потерь (L). Для каждого из 14 352 весов вычисляется соответствующая частная производная. Чем больше абсолютное значение соответствующей частной производной, тем сильнее данный вес влияет на ошибку модели. Совокупность всех частных производных образует градиент функции потерь:

$$\nabla L = \left(\frac{\partial L}{\partial w_1}, \frac{\partial L}{\partial w_2}, \dots, \frac{\partial L}{\partial w_n} \right).$$

Градиент является вектором, указывающим направление наиболее быстрого возрастания функции потерь, т.е. наиболее быстрого возрастания ошибки. В рамках алгоритма обратного распространения ошибки градиент функции потерь последовательно

вычисляется от выходного слоя к предыдущим скрытым слоям: сначала к третьему, затем ко второму и далее к первому.

Для уменьшения ошибки веса обновляются в направлении, противоположном градиенту, согласно правилу градиентного спуска:

$$w_i^{new} = w_i^{old} - \eta \frac{\partial L}{\partial w_i}$$

где w_i^{new} – обновленное значение веса;

w_i^{old} – предыдущее значение веса;

η – скорость обучения (Learning Rate), например, из диапазона $\eta \in [0,0003; 0,003]$;

$\partial L / \partial w_i$ – частная производная функции потерь по весу w_i .

Градиент в приведенной формуле фигурирует со знаком «минус», поскольку он показывает направление роста ошибки, а нейросети следует двигаться в противоположную сторону.

Именно благодаря алгоритму обратного распространения ошибки становится возможным глубокое обучение сети (Deep Learning), упрощенная блок-схема которого приведена на рис. 3. Валидационная выборка помогает оптимизировать модель (например, выбрать приемлемую скорость обучения – параметр η в формуле градиентного спуска) и понять, когда целесообразно остановить обучение. После успешного прохождения «экзамена» на данных тестовой выборки, нейросеть готова к использованию для оценки качества строительства скважин.

Таким образом, применение многослойного персептрона обеспечивает переход от упрощенной линейной схемы оценки качества к интеллектуальной модели, способной учитывать сложные взаимосвязи между технологическими параметрами строительства скважины. Использование механизмов глубокого обучения, функций активации и алгоритмов оптимизации обеспечивает

возможность адаптации модели к изменяющимся производственным условиям и накоплению новых данных. Это создает предпосылки для формирования интеллектуальных систем поддержки принятия решений в области управления качеством буровых работ.

Заключение

Применение нейросетевых моделей позволяет более точно прогнозировать качество строительства скважин в условиях, когда необходимо одновременно учитывать количественные параметры, качественные признаки, неопределенность и искаженные (зашумленные) данные.

Нейросеть может выявлять скрытые закономерности в экспертных решениях, обучаться на прошлых оценках экспертов и автоматически воспроизводить сложную экспертную логику.

Квалиметрические модели являются преимущественно статичными. В отличие от них, нейросетевые модели позволяют переобучать систему на новых данных, учитывать внедрение передовых технологий строительства и проектирования скважин, а также адаптироваться к изменяющимся требованиям отраслевого законодательства.

Преимущество нейросетей в оценке качества заключается в возможности обработки сложных нелинейных зависимостей, снижении влияния человеческого фактора, повышении объективности оценки, автоматизации аналитических процедур, высокой скорости обработки данных и возможности работать с большими массивами информации.

При этом использование нейросетей при оценке качества в бурении имеет ряд ограничений, среди которых следует отметить потребность в достаточном объеме исторических данных по скважинам для обучения модели. Кроме того, для специалистов нейросеть может представлять собой «черный ящик», решения которого сложно интерпретировать. Также функционирование подобных систем ИИ требует наличия соответствующей вычислительной инфраструктуры.

Несмотря на то, что в настоящей работе сделан акцент на преимуществах нейросетевых моделей оценки качества, это не означает отказа от методов квалиметрии. Даже при внедрении систем искусственного интеллекта квалиметрия остается востребованной при решении

таких научно-прикладных задач, как определение граничных условий оценки качества, формирование системы критериев и экспертных оценок.

Наиболее перспективным направлением представляется интеграция методов квалиметрии и искусственного интеллекта в рамках единой интеллектуальной системы оценки качества строительства скважин. В такой модели квалиметрия обеспечивает методологическую основу оценки качества, тогда как нейросетевые алгоритмы реализуют интеллектуальную обработку данных, выявление скрытых закономерностей и адаптацию модели к изменяющимся условиям эксплуатации месторождений.

Таким образом, модели оценки качества строительства скважин на основе нейронных сетей являются мощным драйвером развития современной интеллектуальной квалиметрии. ●

Литература

1. Болотских М., Дорохова М., Серов И., Шуркин М., Бабаева С., Ермолаев Д., Самигуллин А., Белоброва Е., Савушкин Н., Овчаренко С., Колесов А. Искусственный интеллект в России – 2025: тренды и перспективы (Исследование консалтинговой компании «Яков и Партнеры» и «Яндекса»). – Москва, 2025. – 120 с.: ил., табл. URL: yakovpartners.ru / publications / ai-2025.
2. Ahmed A., Kamel M., Elkhatny S. Real-time predictive capabilities of analytical and machine learning rate of penetration (ROP) models // Journal of Petroleum Science and Engineering. – 2019. – Vol. 172. – P. 934–959. – DOI: 10.1016/j.petrol.2018.08.083.
3. Amadi K., Iyalla I., Prabhu R., Alsaba M., Waly M. Development of predictive optimization model for autonomous rotary drilling system using machine learning approach // Journal of Petroleum Exploration and Production Technology. – 2023. – Vol. 13. – P. 2049–2062. – DOI: 10.1007/s13202-023-01656-9.
4. Азгальдов Г.Г., Райхман Э.П. О квалиметрии. Под ред. Гличева А.В. – М.: Издательство стандартов, 1973. – 172 с.
5. Ахмадуллин Э.А. Как измерить качество строительства и капитального ремонта скважин. – Москва, 2025. – 254 с.: ил., табл. – ISBN 978-5-6051035-0-9. URL: www.elibrary.ru / item.asp?id=83259098.
6. Азгальдов Г.Г., Костин А.В., Садовов В.В. Квалиметрия для всех: Учеб. пособие. – М.: ИД «ИнформЗнание», 2012. – 165 с.: ил. – ISBN 978-5-906036-03-2.
7. Ахмадуллин Э.А. Унификация математического аппарата квалиметрии для оценки качества бурения и капитального ремонта нефтяных и газовых скважин // Деловой журн. Neftegaz. RU. – 2025. – № 3. – С. 18–21. – ISSN 2410-3837. URL: magazine.neftegaz.ru / articles / nefteservis / 882308-unifikatsiya-matematicheskogo-apparata-kvalimetrii-dlya-otsenki-kachestva-bureniya-i-kapitalnogo-rem.

KEYWORDS: drilling, drilling quality, quality assessment, qualimetry, neural network, multilayer perceptron.