

# Инженер-нефтяник

спецвыпуск 2024

НАУЧНО-ТЕХНИЧЕСКИЙ ЖУРНАЛ



Санкт-Петербургский  
горный университет  
императрицы Екатерины II



**ХИМПРОМ**

ХИМИЯ БЕЗ ГРАНИЦ



Материалы

III Международной научно-практической конференции

**ПРОРЫВНЫЕ ТЕХНОЛОГИИ В РАЗВЕДКЕ,  
РАЗРАБОТКЕ И ДОБЫЧЕ  
УГЛЕВОДОРОДНОГО СЫРЬЯ**

УДК 550.832: 004.942

# ПРИМЕНЕНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ ГИС-КОНТРОЛЕ СКВАЖИН НГКМ

Бабкин ИВ<sup>1</sup> – к.ф.-м.н./д.т.н., начальник Лаборатории методического обеспечения ГИС

Егурцов СА<sup>1</sup> – президент

Иванов ЮВ<sup>1</sup> – к.т.н., исполнительный директор

Слугин ПП<sup>2</sup> – первый зам. начальника Департамента

Кирсанов СА<sup>2</sup> – к.т.н., начальник Управления

<sup>1</sup>ООО «ИНТ «ГеоСпектр»

<sup>2</sup>ПАО «Газпром», Санкт Петербург

В ближайшее десятилетие приоритетами научно-технологического развития следует считать направления, позволяющие получить значимые научные и научно-технические результаты, создать отечественные наукоемкие технологии [1]. К таким направлениям с полным основанием можно отнести применение методов искусственного интеллекта при обработке данных геофизических исследований скважин нефтегазоконденсатных месторождений (НГКМ) и подземных хранилищ газа (ПХГ).

В процессе разработки НГКМ падение пластового давления и выработка залежей приводят к проявлению обводнения нижней части коллекторов и, следовательно, к падению текущих значений  $K_g$  до значений остаточной газонасыщенности. При интерпретации таких объектов по данным методов ГИС-контроль необходимо повышать точность оценки  $K_g$ , которую не может обеспечить имеющаяся информация о связи скважинных измерений с геофизическими и подсчетными параметрами, полученная на этапе первоначальной оценки запасов, т.к. в процессе эксплуатации в разрабатываемых объектах могут происходить необратимые изменения, приводящие к тому, что полученные на начальном этапе связи между данными методов ГИС и текущим  $K_g$  могут нарушаться. Для обеспечения точности определения текущего  $K_g$ , в том числе и остаточной газонасыщенности, необходимо обобщать всю имеющуюся информацию не только по исследуемой скважине, но и по всему месторождению.

Для решения подобной задачи наиболее эффективным представляется применение искусственного интеллекта на основе технологии нейронных сетей [2], являющейся прорывной активно развиваемой цифровой технологией,

открывающей новые возможности и широкие перспективы в развитии инновационных направлений исследования скважин, позволяющей путем обобщения всего массива имеющейся информации выявлять неизвестные связи между данными методов ГИС-контроль и значениями текущей газонасыщенности.

## Принципы функционирования искусственной нейронной сети

Нейронные сети - мощный и, на сегодня, пожалуй, наилучший метод для поиска решения в ситуациях, когда в экспериментальных данных отсутствуют значительные фрагменты информации, а имеющаяся информация предельно зашумлена. Высокая степень параллельности, допускаемая при реализации нейросистем, обеспечивает быструю обработку больших объемов информации [3]. Помимо этого, нейронная сеть помогает построить функциональную зависимость между данными, подаваемыми на ее вход и выходными данными в том случае, когда они известны. На этом принципе основаны алгоритмы обучения нейронных сетей, которые будут описаны ниже.

Обратные задачи в различных областях геофизики (в т.ч. геоэлектрики [4], ядерной геофизики и т.д.) являются плохо обусловленными и слабо устойчивыми за счет их существенной нелинейности и большой размерности как по числу неизвестных, так и по объему входных данных, а также их зашумленности измерительными погрешностями. Поэтому классические методы решения обратных задач встречаются здесь со значительными трудностями, связанными с большой размерностью и недостатком априорной информации. В данном случае эффективными методами инверсии наблюдаемых данных (т.е. решения обратной задачи геофизики)

и являются методы нейросетевого моделирования.

Искусственная нейронная сеть представляет собой три и более слоя взаимосвязанных элементов-нейронов, из которых первый слой формирует входные данные, а последний – выходные. Как правило, на несколько входов приходится один выход. Внутренние слои сети обрабатывают и накапливают поступившую информацию. Каждый нейрон имеет свой весовой коэффициент и участвует во взвешенном суммировании. Таким образом, на выходе сети получается сигнал, сформированный из взвешенных сумм входных сигналов на каждом слое сети. Подбор весовых коэффициентов каждого нейрона позволяет получить при данных входах практически любой выходной сигнал. Результатом работы сети и является набор весовых коэффициентов, преобразующих входные сигналы в тот выходной, который требуется получить [5].

Типичной нейронной сетью является персептрон. Он состоит из элементов трех типов (рис. 1). Входной слой (*S*-элементы) воспринимает внешний сигнал, внутренние слои (*A*-элементы) его обрабатывают, а выходной слой (*R*-элементы) выдает обработанный персептроном сигнал.

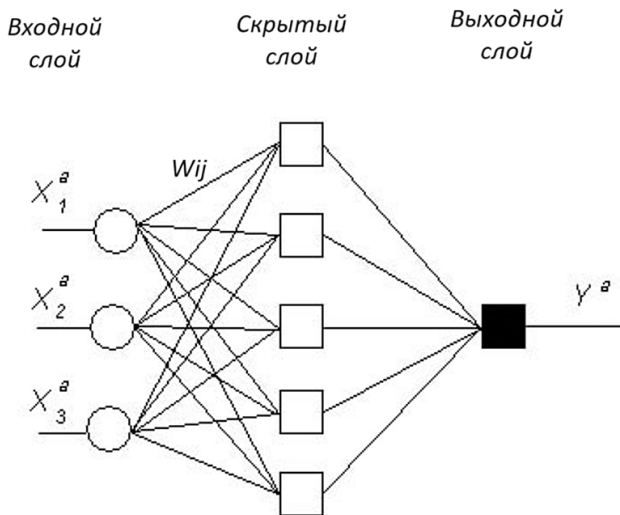


Рис. 1. Элементарный персептрон

Каждому нейрону приписывается весовой коэффициент  $W_{ij}$ , участвующий во взвешенном суммировании. Выходной сигнал  $Y$  представляется в виде линейной комбинации сигналов  $X$ , поданных на вход, т.е.

$$Y_i = \sum_j W_{ij} X_j \quad (1)$$

Выходной сигнал самого нейрона формируется с помощью передаточной функции  $f(x)$ . В настоящей работе в ее качестве использовалась сигмоидальная функция (сигмоида) вида:

$$f(x) = 1/(1+\exp(-x)) \quad (2)$$

Таким образом, правильность настройки нейросети на решение конкретной задачи состоит в корректном выборе весовых коэффициентов связей каждого нейрона предыдущего слоя с каждым нейроном последующего слоя  $W_{ij}$ . Процедура подстройки весовых коэффициентов называется обучением сети. Для проведения обучения необходимо иметь обучающую выборку, т.е. многомерный вектор входных значений (например, показания комплекса методов ГИС на каждом шаге глубины) и соответствующий им вектор выходных значений (например, величина  $K_j$ ). Корректность выбора обучающей выборки является залогом всей процедуры обучения.

### Особенности обучения нейросети по данным ГИС

Стандартной моделью персептрона является многослойный персептрон, содержащий помимо входного и выходного слоя несколько внутренних (скрытых) слоев нейропроцессорных элементов [6]. Каждый нейрон следующего слоя принимает и обрабатывает сигналы от всех нейронов предыдущего слоя, передавая сигнал от входного через несколько скрытых слоев к выходному слою нейронов. Такая архитектура делает нейронную сеть более универсальной к предъявляемым ей обучающим выборкам, но и усложняет процесс ее обучения.

Процедура обучения нейронной сети будет наиболее эффективной в том случае, если подаваемые ей на вход значения будут близки между собой. При этом сами эти значения должны находиться в диапазоне (0, 1). Таким образом, все показания методов ГИС должны нормироваться по опорным пластам, используя двойной разностный параметр.

Механизмы обучения нейронной сети основаны на методе обратного распространения ошибок. Это итерационная процедура, когда вначале задается произвольный набор весовых коэффициентов нейронов, по которым определяется выходной сигнал. Далее определяется функция ошибки, как степень отклонения полученного сигнала от эталонного. Она играет роль учителя, позволяя корректировать процесс подбора коэффициентов. На основании ее определяются поправки в весовые коэффициенты, после чего вся процедура повторяется вновь. Критерием окончания итераций является достижение уровня ошибки меньше заданного, требуемого для решения задачи с необходимой точностью.

Рассмотрим более подробно процесс обучения двухслойного персептрона [3].

Пусть имеется набор пар векторов  $(x^a, y^a)$ ,  $a = 1 \dots p$ . Задачей, которая ставится перед нейронной сетью, является получение на ее выходе вектора  $y^a$  всякий раз при подаче на входы сети вектора  $x^a$ . Это достигается путем подстройки весовых коэффициентов  $W$  каждого нейрона, сам процесс подстройки называется обучением, а пара векторов  $(x^a, y^a)$  – обучающей выборкой.

Метод обучения такой нейросети является итерационным алгоритмом, последовательно уменьшающим ошибку в выходных векторах, и включает несколько этапов:

- 1) Задание начальных значений матрицы весов  $W$  случайным образом.
- 2) Вычисление для них выходного образа  $y^a$  для каждого  $x^a$ .
- 3) Вычисление функции ошибки  $\delta^a = y^a - y^a$ .
- 4) Модификация матрицы весов пропорционально функции ошибки.

Нейронная сеть, выполняющая преобразование  $F: X \rightarrow Y$  векторов  $X$  из пространства входов  $X$  в вектора  $Y$  выходного пространства  $Y$  характеризуется матрицей состояния  $W$ . Полная ошибка  $E$  сети в состоянии  $W$  для обучающей выборки  $(X^a, Y^a)$ :

$$E = E(W) = \sum_a || F(X^a, W) - Y^a || = \sum_a \sum_i (F_i(X^a, W) - Y_i^a)^2 \quad (3)$$

Здесь суммирование ведется по всем входным векторам, образующим обучающую выборку.

Ошибка  $E$ , по определению, принимает неотрицательные значения, а в некотором обученном состоянии  $W^*$  она равна нулю, т.е. сеть не делает ошибок на обучающей выборке, поэтому обученные состояния являются точками минимума функции  $E(W)$ .

Таким образом, задача обучения нейронной сети является задачей поиска минимума функции ошибки в пространстве состояний, и, следовательно, для ее решения могут применяться стандартные методы многомерной оптимизации, основанные на методах градиентного спуска.

Качество и скорость минимизации по методу градиентного спуска сильно зависят от выбора начального приближения, откуда начинается расчет, чтобы не попасть в области значений, где минимизируемая функция меняется очень слабо (тогда скорость обучения будет стремиться к бесконечности), либо имеет локальные минимумы (тогда при обучении будет получено неверное решение). Поэтому перед проведением обучения необходимо случайным образом задать несколько начальных значений весовых коэффициентов и на небольшом объеме выборки проследить поведение ошибки. Тот вариант, который будет минимизировать ошибку наиболее эффективно и является тем начальным приближением, которое следует использовать при обучении.

Важным вопросом является также критерий окончания обучения. Здесь необходимо подобрать минимально необходимое число итераций (эпох), при котором итерационный процесс будет сходиться к искомому решению (ошибка будет уменьшаться). При увеличении числа эпох зачастую возникает явление переобучения – когда после определенного числа эпох ошибка начинает вновь возрастать. Для того, чтобы этого избежать, исходная обучающая выборка разбивается на три – выборку обучения, выборку валидации (равные по числу обучающих векторов)

и тестовую выборку (с числом векторов, значительно меньшим, чем в первых двух). Вектора в каждую из трех выборок отбираются из начальной обучающей выборки случайным образом. Затем для первых двух выборок процесс обучения идет параллельно, при этом сравниваются ошибки нейросети на каждой из них после каждой эпохи обучения. Разница между этими ошибками должна уменьшаться. Эпоха, на которой эта разница вновь начинает увеличиваться, характеризует начало переобучения, а на предшествующей ей, отвечающей минимальной ошибке, нейросеть считается обученной. Качество обучения проверяется на тестовой выборке и, при неудовлетворительном результате, запускается процедура переобучения – вектора всех трех выборок вновь объединяются в одну, из них выбираются новые выборки и обучение начинается сначала.

### Пример использования нейросетевых технологий

Решающую роль для качественной работы нейронной сети имеет построение обучающей выборки, которая должна быть достаточно представительной, чтобы содержать большинство возможных вариантов литотипов коллекторов, встречающихся на исследуемом НГКМ либо объектов хранения на ПХГ, и иметь объем данных, достаточный для проведения обучения сети с требуемой точностью оценки текущего Кг. Вся обучающая выборка делится на три части – собственно обучающая, выборка валидации (обе равные по объему) и тестовая выборка (меньшая по объему, чем первые две), далее элементы каждой выборки тасуются случайным образом и подаются на вход обучающего алгоритма до тех пор, пока суммарная ошибка нейронной сети уменьшается с ростом числа обучений (эпох). Первые две выборки нужны для оценки сходимости процедуры обучения, тестовая выборка применяется для контроля процесса обучения нейронной сети.

Обученная таким образом нейронная сеть может успешно решать задачи выделения типов коллекторов по градиентам значений текущего Кг на основе данных ГИС-контроля с привлечением всей доступной информации по месторождению или ПХГ.

Задача определения текущей газонасыщенности продуктивных коллекторов в скважинах сложной многоколонной конструкции встает при проведении комплекса ГИС на газовых и газоконденсатных месторождениях и ПХГ. Такие скважины имеют несколько обсадных колонн и НКТ, что не позволяет получать достоверную информацию о состоянии заколонного пространства, используя только стандартный комплекс ГИС (основными методами в котором являются ГК и нейтронный гамма-каротаж – НГК). Наиболее эффективным в технически сложных условиях многоколонных конструкций газовых скважин является метод импульсного нейтрон-нейтронного каротажа (ИННК), который обычно не включается в стандартный комплекс применяемых методов

в силу дороговизны приборов и трудоемкости его обработки, поэтому измерения проводят лишь в нескольких скважинах [7]. Однако эффективность ИННК делает актуальной задачу разработки технологии обобщения результатов, полученных по отдельным скважинам, и их распространения на всю площадь.

Процедура определения газонасыщенности с использованием нейронных сетей и метода ИННК показана на примере двух валанжинских газовых скважин одного из месторождений Западной Сибири. В этих скважинах был выполнен одинаковый комплекс ГИС-бурение, а ГИС-контроль в скважине «А» включал еще и ИННК, по которому в ней определялся  $K_2$ .

В скважине Б  $K_2$  определялся по тому же комплексу методов на основе нейронной сети, обученной на данных скважины А [8] и сопоставлялся с  $K_2$ , оцененному по ИННК. Обе скважины в исследуемых интервалах разреза, пересекающих пласты БУ-8 – БУ-12, были перекрыты 168 мм-колонной и НКТ диаметром 101.6 мм (рис.2).




Рис. 2. Корреляция разрезов скважины А (с известным  $K_2$ ) и скважины Б

Набор входных данных, включающий обработку методов ГИС-бурение (пористость по НГК  $K_p(J_{нгко})$ , амплитуду ПС  $A_{пс}$ , двойной разностный параметр по ГК  $dJ_{гк}$ ) и ГИС-контроль (НГК в колонне  $J_{нгк}$ )  $\{K_p(J_{нгко}), A_{пс}, dJ_{гк}, J_{нгк}\}$  и соответствующий им набор значений  $\{K_2(\text{ИННК})\}$  для скважины А составили обучающую выборку, набор входных данных  $\{K_p(J_{нгко}), A_{пс}, dJ_{гк}, J_{нгк}\}$  для скважины Б составили рабочую выборку, для которой требовалось определить значения  $K_2$ . При этом все исходные продуктивные пласты разбиты на пропластки по  $J_{нгко}$ , по которым проводилось усреднение входных и выходных данных для обеих скважин.

Для обучающей выборки проводится процедура обучения нейронной сети. Сходящийся итерационный процесс при большом числе итераций (называемых эпохами) позволяет вычислить весовые коэффициенты, которые связывают входные значения  $\{K_p(J_{нгко}), A_{пс}, dJ_{гк}, J_{нгк}\}$  с выходным значением  $K_2$  для данного вектора. Их совокупность для всех векторов обучающей выборки формирует матрицу весовых коэффициентов.


В начале процесса обучения весовые коэффициенты задаются случайным образом, определяя все их значения на каждом слое сети, определяют выходное значение нейронной сети, которое сопоставляется с известным для этого вектора обучающей выборки значением  $K_2$ . Функция ошибки между полученным и истинным значением, выполняющая роль «учителя», участвует в подстройке каждого весового коэффициента, которые затем вновь используются для определения выходного значения нейронной сети, и процедура повторяется, пока не будут исчерпаны все итерации.

По завершении процесса обучения определяется набор весовых коэффициентов, с которыми каждый из методов ГИС вносит свой вклад в искомую величину, и, таким образом, создается многомерная квазилинейная зависимость  $K_2$  от  $K_p(J_{нгко}), A_{пс}, dJ_{гк}, J_{нгк}$ . После этого нейросеть готова к работе.

При поступлении на вход алгоритма новых векторов из пространства  $\{ K_p(J_{\text{НГКО}}), A_{\text{ПС}}, dJ_{\text{ГК}}, J_{\text{НГК}} \}$ , на основе полученных при обучении весовых коэффициентов определяется результирующее значение  $K_r$  для них. Если на основе какой-либо дополнительной информации результат признан неудовлетворительным, то можно провести процедуру дообучения нейронной сети, добавив в исходную обучающую выборку дополнительные вектора.

Необходимо отметить, что процедура обучения проводится один раз, создавая вектора весов для каждого нейрона, составляющих весовую матрицу  $W$ . Эта процедура является достаточно времяземкой, так как процесс поиска решения проводится итерационно. В дальнейшем полученная весовая матрица используется для определения искомого параметра в рабочей выборке, и эта процедура является на несколько порядков более быстрой, чем процесс обучения.

Результат применения разработанного алгоритма определения газонасыщенности в скважине Б на основе настроенной по данным скважины А нейронной сети представлен на рис. 3. В скважине Б проводился полный комплекс стандартных методов ГИС, кроме того, в ней был проведен и ИННК, который использовался для контроля полученного по нейросетевому алгоритму результата. Сравнение полученных значений  $K_r$  со значениями  $K_r$  текущего, определенными по ИННК и меняющимися в диапазоне от 0.2 до 0.85 показало, что при объеме рабочей выборки в 240 векторов максимальное значение отклонения составило 0.15, при этом в 79% случаев оно составило менее 0.1. Этот результат можно улучшить, взяв более богатую и представительную обучающую выборку и привлекая данные по большему количеству методов ГИС.



**Рис. 3. Сопоставление значений  $K_r$  текущее (красная кривая) с его нейросетевой аппроксимантой (синяя кривая)**

Таким образом, применение нейросетевого алгоритма позволяет при определении текущей газонасыщенности в рабочей выборке исключить из комплекса методов ГИС метод ИННК, при этом используя результаты определения  $K_r$  по нему.

Это достигается путем применения в небольшом количестве базовых скважин полного комплекса методов (по открытому стволу + ГК + НГК + ИННК), выявления в них в процессе обучения зависимостей для весовых коэффициентов алгоритма, которые затем будут использованы в тех скважинах, где ИННК не проводился.

#### Заключение

В работе показан пример применения элементов искусственного интеллекта для обработки материалов ГИС, в частности, решения задачи оценки газонасыщенности в неоконских отложениях на одном из месторождений Западной Сибири. Решение данной задачи можно уточнить, применив расширенный комплекс методов ГИС и используя обучающую выборку большей размерности, составленной на основе измерений в неоконских измерениях группы скважин схожей конструкции.

Технологии искусственных нейронных сетей являются современным эффективным математическим инструментом и имеют большие перспективы для решения геофизических задач, связанных с оценкой насыщения коллекторов.

ЛИТЕРАТУРА

1. О стратегии научно-технологического развития Российской Федерации: указ Президента РФ от 28.02.2024 № 145 // Собр. Законодательства РФ. – 2024. – № 10. – ст. 1373(4653).
2. Рашид Т. Создаем нейронную сеть. Пер. с англ. – СПб.: ООО «Диалектика» – 2019. – 272 с.
3. Уоссермен Ф. Нейрокомпьютерная техника. Москва: Мир, 1992. – 236 с.
4. Шимелевич М.И. Методы повышения устойчивости инверсии данных геоэлектрики на основе нейросетевого моделирования // Геофизика. 2013. № 4. С. 49-55.
5. Судариков В.А. Исследование адаптивных нейросетевых алгоритмов решения задач линейной алгебры // Нейрокомпьютер. 1992. № 3,4. С. 13-20.
6. Рутковская Д., Пилинский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. М.: Горячая линия – Телеком, 2008. 383 с.
7. Малев А.Н., Бабкин И.В. Исследование методических возможностей двухзондового импульсного нейтрон-нейтронного каротажа для определения текущей газонасыщенности // НТВ «Каротажник». 2007. № 162. С. 153-168.
8. Бабкин И.В. Технология определения газонасыщенности продуктивных коллекторов по данным ядерно-геофизических методов ГИС в обсаженных газовых скважинах, диссертация на соискание ученой степени доктор технических наук. М., 2014. – 214 с.

REFERENCES

1. On the strategy of scientific and technological development of the Russian Federation: Decree of the President of the Russian Federation No. 145 dated 02/28/2024 // Sobr. Legislation of the Russian Federation. - 2024. - No. 10. – Art. 1373(4653).
2. Rashid T. Creating a neural network. Translated from English – St. Petersburg: Dialectics LLC – 2019. – 272 p.
3. Wasserman F. Neurocomputer technology. Moscow: Mir, 1992. – 236 p.
4. Shimelevich M.I. Methods of increasing the stability of inversion of geoelectrics data based on neural network modeling // Geophysics. 2013. No. 4. pp. 49-55.
5. Sudarikov V.A. Research of adaptive neural network algorithms for solving linear algebra problems // Neurocomputer. 1992. No. 3,4. pp. 13-20.
6. Rutkovskaya D., Pilinsky M., Rutkovsky L. Neural networks, genetic algorithms and fuzzy systems. M.: Hotline – Telecom, 2008. 383 p.
7. Malev A.N., Babkin I.V. Investigation of the methodological possibilities of two-probe pulsed neutron-neutron logging to determine the current gas saturation // NTV "Logger". 2007. No. 162. pp. 153-168.
8. Babkin I.V. Technology for determining the gas saturation of productive reservoirs according to nuclear geophysical GIS methods in cased gas wells, dissertation for the degree of Doctor of Technical Sciences. M., 2014. – 214 p.

**ХИМПРОМ ХИМИЯ БЕЗ ГРАНИЦ**

В 2024 году свои двери открыла лаборатория буровых растворов компании «Химпром». Научно-исследовательская деятельность остается приоритетной для компании. Каждая задача наших партнеров требует комплексного исследования, индивидуального подхода и уникальных технологических решений.

**Задачи, которые готова решать лаборатория буровых растворов «Химпром»:**

- Разработка рецептур систем буровых растворов.
- Модификация существующих продуктов под индивидуальные условия заказчика.
- Поиск новых продуктов под требования заказчика.

С «Химпром» вы получаете партнера, который ценит качество и надежность на каждом этапе сотрудничества. Мы гордимся возможностью предложить нашим клиентам уникальные решения, которые способствуют успешному завершению проектов любой сложности. Открыты для диалога и готовы взять на себя самые амбициозные задачи!

8 800 250 94 74  
 info@himprom-group.ru  
 www.himprom-group.ru

Реклама