

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ В ОБРАТНОЙ ЗАДАЧЕ ДВУХФАЗНОЙ ФИЛЬТРАЦИИ

Ю.А. Гончарова¹, И.М. Индрупский^{2,1}
1 – РГУ нефти и газа (НИУ) имени И.М. Губкина,
2 – ИПНГ РАН
e-mail: goncharova97st@mail.ru

Введение

Обратные задачи фильтрации возникают во многих востребованных практических приложениях. Наибольшую сложность в методическом и вычислительном плане представляют собой случаи, когда идентифицируется значительное число разноплановых параметров, а решение прямой задачи осуществляется численными методами. В частности, это характерно для важной практической проблемы адаптации гидродинамических моделей нефтяных и газовых залежей к истории их разработки. А также для современных численных моделей в области гидродинамических исследований скважин (ГДИС).

Прямой задачей называется задача определения на основе известных свойств пласта и пластовых флюидов неизвестных распределений давления, насыщенностей фаз в пласте на разные моменты времени, а также забойных давлений и дебитов скважин во времени. Прямая задача основывается на математической модели фильтрации (в общем случае – трехмерной, многофазной, в области сложной геометрии, с учетом неоднородности и анизотропии характеристик пласта) и обычно решается численными методами. Обратная задача заключается в коррекции входных данных прямой задачи (свойств пласта и пластовых флюидов) по данным реальных измерений, проводимых на месторождении и по объему соответствующих некоторому подмножеству показателей, определяемых из решения прямой задачи. Необходимость решения обратной задачи возникает из-за ряда неустранимых проблем с полнотой, точностью и достоверностью исходных данных для прямой задачи, возникающих в связи с точечным характером керновых и скважинных геофизических данных, несоответствием масштаба и условий проведения лабораторных измерений реальным процессам в пласте, косвенностью и недостаточной разрешающей способностью объемных геофизических методов (сейсмика).

В случае численного решения прямой задачи обратную задачу формулируют и решают в оптимизационной постановке. Это означает, что за счет корректировки входных данных для прямой задачи минимизируется критерий качества (функционал),

характеризующий степень отклонения результатов решения прямой задачи от фактически измеренных показателей работы скважин.

Для решения обратных задач применяют широкий спектр оптимизационных алгоритмов [1–3]. Несмотря на их существенное различие, общим является необходимость решения серии прямых задач с разными наборами входных данных и определения соответствующих значений критерия качества в процессе итерационного (или «ансамблевого», основанного на наборе реализаций) решения обратной задачи. В зависимости от сложности математической модели, выбранного численного метода и метода оптимизации многократное решение прямой задачи может требовать тех или иных затрат вычислительного времени и ресурсов. Однако в любом случае именно эта составляющая при решении обратных задач является наиболее емкой в вычислительном плане. Таким образом, возможность быстрого вычисления величины критерия качества представляет собой крайне актуальную проблему с теоретической и практической точек зрения.

Определенным шагом в данном направлении являются прокси-модели, которые нашли применение в специализированных программных пакетах и опциях гидродинамических симуляторов для решения задач адаптации к истории разработки и оценки неопределенности (Schlumberger MEPO, Roxar Enable, RFD tNavigator и др.). Однако качество прокси-моделей существенно зависит от числа используемых опорных решений прямой задачи и сильно ухудшается в случае большого числа разнохарактерных входных данных, а также сильной нелинейной зависимости от них решения. С этой точки зрения интересна возможность использования альтернативного подхода – методов машинного обучения – для ускоренного вычисления величины критерия качества по заданным входным параметрам модели (вместо классического решения прямой задачи с использованием численных методов).

В качестве примера для рассмотрения выбраны прямая и обратная задачи специализированных двухфазных исследований скважин с закачкой в пласт воды для оценки функций относительных фазовых проницаемостей (ОФП) [4, 5]. Несмотря на относительную простоту постановки прямой задачи, в сравнении с задачами адаптации 3D-моделей к истории разработки, она отражает основные особенности данного класса задач: разнохарактерность идентифицируемых параметров, существенную нелинейность, необходимость привлечения численных методов в рамках прямой и обратной задач,

использование критерия взвешенных наименьших квадратов для набора измеряемых показателей работы скважины.

Классическая постановка задачи

В отличие от традиционных задач ГДИС, основанных на моделях однофазной фильтрации, в данном исследовании рассматриваются комплексные ГДИС с принудительным созданием в окрестности скважины двухфазных фильтрационных течений (нефть + вода) с большим диапазоном изменения водонасыщенности пласта вблизи скважины [4, 5]. В число идентифицируемых параметров, определяемых по результатам решения обратной задачи, включаются функции ОФП для нефти и воды. Таким образом, прямая задача формулируется на основе модели двухфазной фильтрации. Схематично отличие рассматриваемой задачи от традиционных задач ГДИС иллюстрирует рис. 1.




Рис. 1. Схематизация традиционного и рассматриваемого подходов к исследованию нефтяных скважин

Типичное исследование включает 4 основных этапа [5]. На первом этапе, до момента времени T_1 , скважина отбирает пластовый флюид (при отсутствии подвижной пластовой воды – нефть) с заданным (возможно, переменным) дебитом по жидкости. В период с T_1 по T_2 скважина закрыта для записи кривой восстановления давления (КВД). С T_2 по T_3 скважина осуществляет функции нагнетательной: в пласт закачивают воду с заданным, в общем случае переменным, расходом. С момента T_3 до T_4 осуществляется обратный отбор флюидов из пласта с заданным (также, возможно, переменным) дебитом по жидкости: сначала практически чистой воды, затем воды с нарастающей долей нефти, вплоть до снижения обводненности продукции до исходных или близких к исходным значений.

В предшествующих работах было показано, что реализация такого исследования с соответствующим гидродинамическим и геофизическим контролем позволяет путем решения обратной задачи уточнять следующие параметры продуктивного пласта [5–9]:

- 1) коэффициент пористости m ;
- 2) коэффициент проницаемости k ;
- 3) коэффициент проницаемости скин-зоны пласта k_s ;
- 4) пороги подвижности (остаточные насыщенности) нефти (S_n^*) и воды (S_v^*);
- 5) параметры относительных фазовых проницаемостей для нефти и воды как функций коэффициентов нефте- (водо-)насыщенности.

Относительные фазовые проницаемости для нефти и воды задаются как параметрические зависимости из некоторого класса, например, в виде степенной зависимости

$$\begin{aligned} k_\alpha &= 0, & S_\alpha < S_\alpha^*, \\ k_\alpha &= C_\alpha (S_\alpha - S_\alpha^*)^{n_\alpha}, & S_\alpha^* \leq S_\alpha \leq 1 - S_\lambda^*, \end{aligned} \quad (1)$$

где k_α – величина относительной проницаемости пласта по фазе α ; S_α – насыщенность пласта данной фазой; S_α^* – порог подвижности данной фазы; S_λ^* – порог подвижности другой фазы (то есть $\lambda = n$, если $\alpha = v$, и $\lambda = v$, если $\alpha = n$). Через n_α и C_α обозначены неизвестные коэффициенты, которые вместе с порогами подвижности и ФЕС пласта подлежат идентификации по данным исследования скважины. Индексы α и λ обозначают фазу: n – для нефти, v – для воды.

В *прямой задаче* перечисленные параметры используются, наряду с другими параметрами пласта и флюидов, а также начальными и граничными условиями, в качестве входных данных для вычисления показателей работы скважины в процессе исследования. В качестве таковых рассматриваются динамики изменения во времени давления на забое скважины, водонасыщенности в околоскважинной зоне и дебита скважины по нефти. Поскольку некоторые этапы исследования подразумевают наличие существенно двухфазных фильтрационных течений, прямая задача в наиболее простом (одномерном осесимметричном) случае сводится к необходимости решения следующей системы нелинейных дифференциальных уравнений [5]:

$$\frac{\partial}{\partial u} \left(\frac{k k_\alpha \rho_\alpha}{\mu_\alpha} \frac{\partial p_\alpha}{\partial u} \right) = R_k^2 e^{2u} \frac{\partial}{\partial t} (m S_\alpha \rho_\alpha), \quad \alpha = n, v. \quad (2)$$

Начальные условия записываются в виде

$$P_{\text{н}}(u)|_{t=0} = p_0, S_{\text{в}}(u)|_{t=0} = S_{\text{в}}^* . \quad (3)$$

Граничные условия на внешнем контуре пласта принимаются в виде

$$\frac{dp_{\alpha}}{du} \Big|_{u=0} = 0, \alpha = \text{н, в} . \quad (4)$$

Здесь p_{α} – давление в фазе α ; $\rho_{\alpha}, \mu_{\alpha}$ – плотность и вязкость соответствующей фазы; m, k – коэффициенты пористости и проницаемости; k_{α} – относительная фазовая проницаемость для фазы α ; S_{α} – коэффициент насыщенности порового пространства фазой α ; $u = \ln \frac{r}{R_{\text{к}}}$ и t – логарифмическая пространственная и временная координаты; p_0 – начальное пластовое давление; $R_{\text{к}}$ – радиус внешней границы пласта.

Влияние скин-фактора учитывается путем задания различных значений коэффициента проницаемости для скин-зоны и основной части пласта, то есть при $R_{\text{с}} \leq r \leq R_{\text{с}}$ значение k меняется на $k_{\text{с}}$. Граничные условия на стенке скважины соответствуют заданным условиям на дебит жидкости или расход воды, в зависимости от этапа исследования скважины, и выражаются условиями второго рода для давления [5].

В рамках разработанной ранее в ИПНГ РАН программной реализации решения прямой задачи применяется численный метод, основанный на методе конечных разностей [5]. Система разностных уравнений решается в переменных $[p_{\text{н}}, S_{\text{в}}]$. В общем случае используется неравномерная блочно-центрированная сетка по логарифмической пространственной координате u с числом узлов, достигающих сотен единиц при необходимости точного отслеживания фронта насыщенности. Для учета слоистой неоднородности пласта может также использоваться осесимметричная 2D постановка в цилиндрических координатах r - z [5] или 3D постановка, что приводит к дальнейшему увеличению размерности прямой задачи.

Обратная задача состоит в поиске таких значений идентифицируемых параметров, которые обеспечивают максимальную близость решения прямой задачи к данным реальных измерений на скважине. Минимизируемый функционал представляет собой взвешенный критерий наименьших квадратов и принимает следующий вид [5]:

$$J(\vec{u}) = \sum_{j=1}^N [C_p (p_{\text{р}}^j - p_{\text{ф}}^j)^2 + C_s (S_{\text{р}}^j - S_{\text{ф}}^j)^2 + C_q (Q_{\text{р}}^j - Q_{\text{ф}}^j)^2] . \quad (5)$$

Здесь \vec{u} – вектор идентифицируемых (управляющих) параметров, перечисленных выше под номерами 1–5; j – номер замера на скважине, N – количество моментов замеров; p^j, S^j, Q^j – соответственно давление на забое скважины, водонасыщенность

околоскважинной зоны и дебит по нефти на момент проведения j -ого замера. Индекс «р» соответствует значениям, посчитанным при решении прямой задачи, индекс «ф» – фактически замеренным на скважине. Весовые коэффициенты C_p , C_s , C_Q служат для нормировки разномасштабных величин, учета погрешностей измерений и регулирования влияния отдельных показателей на величину функционала качества (5).

Независимо от выбора конкретного алгоритма минимизации функционала (5) при решении обратной задачи, на каждой его итерации требуется определять значения критерия качества $J(\vec{u})$ для текущей комбинации значений идентифицируемых параметров. Что в классическом подходе подразумевает, в свою очередь, очередной прогон численного решения прямой задачи.

Таким образом, возникает вопрос о возможности обойти вычислительно затратное решение прямой задачи численными методами на каждой итерации обратной задачи. Для этого в данной работе привлекаются методы машинного обучения, а именно, искусственная нейронная сеть.

Построение нейронной сети

Искусственная нейронная сеть (нейросеть, НС) – это математическая модель, представляющая собой систему соединенных и взаимодействующих между собой искусственных нейронов. Структура нейросети состоит из нейронов и синапсов. Нейрон – это вычислительная единица, которая получает информацию, производит над ней простые вычисления и передает ее дальше. Между собой нейроны связаны синапсами, которые при передаче сигнала от одного нейрона к другому изменяют этот сигнал с помощью единственного параметра – веса. Так, нейрон получает суммарный сигнал от всех предыдущих нейронов и обрабатывает его с помощью функции активации [10], которая нормализует сигнал в приемлемое значение. Более подробно о нейросетях можно прочитать в специализированной литературе [11]. На рис. 2 показана для примера структура простейшей нейросети – персептрона.

Рассматриваемая задача состоит в следующем. При известных фактически замеренных показателях работы скважины необходимо по заданной комбинации значений идентифицируемых параметров \vec{u}_i получать значение функционала качества (5) за счет аппроксимации зависимости $J(\vec{u})$ нейронной сетью:

$$J_i = J(\vec{u}_i) \quad (6)$$




Рис. 2. Простейшая нейронная сеть (персептрон)

В целом процедура построения аппроксимирующей НС осуществляется следующим образом. Сначала под свойства задачи подбираются оптимальная модель НС и подходящий алгоритм ее обучения. Далее генерируется обучающая выборка в соответствии с методами планирования эксперимента. Обучающая выборка представляет собой набор различных пар (вектор входных параметров \vec{u}_i – значение функционала качества $J(\vec{u}_i)$). Далее производится обучение НС, то есть оптимизация весов синапсов, на обучающей выборке. Для оценки качества аппроксимации обученной НС используется отдельная контрольная выборка, составленная из пар $(\vec{u}_i - J(\vec{u}_i))$, не присутствовавших в обучающей выборке, но входящих в допустимый диапазон значений параметров.

Опишем подробнее параметры, с которыми работает НС в рассматриваемой задаче. На вход подается вектор значений управляющих параметров, на выходе – одно значение функционала. Параметры пласта определяются в соответствии с концепцией эффективного порового пространства (ЭПП) [5]. В каждой i -ой комбинации задаются значения 7-ми различных параметров: коэффициента эффективной пористости пласта m_i , коэффициента эффективной проницаемости пласта k_i , коэффициента эффективной проницаемости скин-зоны k_{si} , порога подвижности нефти S_{ni}^* (нормированного по эффективному поровому объему), коэффициента C_{ni} степенной функции ОФП для воды, показателей степени n_{vi} и n_{ni} функций ОФП для воды и для нефти соответственно. При этом $S_v^*=0$ и $C_n=1$ по определению в соответствии с нормировкой насыщенностей и ОФП в концепции ЭПП. Также актуальна задача определения вертикальной проницаемости [12], но в данном исследовании она не рассматривается.

Для построения обучающей и контрольной выборок приняты следующие диапазоны допустимых значений параметров:

- $m \in [0,05; 0,3]$, д.ед.;
- $k \in [0,1; 0,7]$, Дарси;
- $k_s \in [0,005; 0,05]$, Дарси;
- $S_{hi}^* \in [0,05; 0,6]$, д.ед.;
- $C_b \in [0,1; 1]$, б/р;
- $n_b \in [1; 3]$, б/р;
- $n_n \in [1; 3]$, б/р.

Для каждой комбинации \vec{u}_i осуществлялось решение прямой задачи с использованием вычислительной программы ИПНГ РАН и по формуле (5) определялось соответствующее значение критерия качества:

$$J_i = J(m_i, k_i, k_{si}, S_{hi}^*, C_{bi}, n_{bi}, n_{ni}). \quad (7)$$

В качестве фактически замеренных показателей работы скважины в функционале (5) также принимались результаты решения прямой задачи, но при фиксированных значениях управляющих параметров \vec{u}^* , рассматриваемых как истинные.

На рис. 3–6 показаны графики зависимостей величины функционала от отдельных идентифицируемых параметров при условии, что значения остальных параметров соответствуют истинным. Зависимости являются гладкими, но имеют различный характер, сильно различаются по диапазону значений и асимметричны по отношению к точке истинной величины параметра ($J=0$).




Рис. 3. Зависимость функционала качества от пористости




Рис. 4. Зависимость функционала качества от порога подвижности нефти




Рис. 5. Зависимость функционала качества от C_B




Рис. 6. Зависимость функционала качества от n_B

Подготовка обучающей выборки

Правильный подбор обучающей выборки играет важную роль для лучшего описания поведения аппроксимируемой функции в области допустимого изменения параметров. В случае, если аппроксимирующая функция близка к линейной по всем аргументам, хорошая обучающая выборка может быть построена как двухуровневый полный факторный эксперимент (ПФЭ) [13], то есть составлена из всевозможных комбинаций максимальных и минимальных допустимых значений параметров.

В нашем случае на вход НС подается 7 различных параметров, следовательно, имеется 7 факторов. Двухуровневый ПФЭ соответствует объему выборки $2^7 = 128$ обучающих пар $(\vec{u}_i - J(\vec{u}_i))$. Однако, учитывая существенно немонотонный характер зависимости функционала качества от идентифицируемых параметров (см. рис. 3–6), для качественного описания функции требуется привлечение дополнительных комбинаций с использованием промежуточных значений каждого параметра. В то же время, даже трехуровневый ПФЭ уже предполагает использование более двух тысяч элементов выборки, что делает его неприемлемым для рассматриваемой задачи.

Учитывая перечисленные особенности, авторами было предложено обучающую выборку составить из двух двухуровневых ПФЭ. В первом и втором ПФЭ один уровень задавался близким соответственно к левой или правой границе области допустимого изменения параметра, а второй уровень – к точке минимума функционала по данному параметру (см. рис. 3–6). Итого подготовленная выборка насчитывала 256 обучающих пар $(\vec{u}_i - J(\vec{u}_i))$. Рис. 7 показывает, как изменяются значения функционала в зависимости от номера обучающей пары в выборке.

После того, как выборка для обучения готова, параметры необходимо нормировать. В данном случае использовалась естественная нормировка $\tilde{x}_{ij} = \frac{x_{ij} - x_{minj}}{x_{maxj} - x_{minj}}$, где i – номер элемента выборки, j – номер параметра (фактора).

Определение структуры НС

Рассматриваемая задача характеризуется 7 входными параметрами и 1 неизвестным значением функционала, которое необходимо определить. Поэтому очевидно, что НС на входном слое должна иметь 7 нейронов, на выходном – 1.




Рис. 7. Значения функционала на обучающей выборке

Для лучшей аппроксимации функции и во избежание проблем с обучением из-за использования несмещенной функции активации, дополнительно в сеть добавлен нейрон смещения на каждый слой, кроме выходного [11]. Таким образом, входной слой содержит 8 нейронов.

Следующим шагом является выбор количества скрытых (промежуточных) слоев в нейронной сети и числа нейронов в них. В теории НС существуют теоремы [14], позволяющие определить необходимое количество скрытых слоев в зависимости от характера поставленной задачи. В данном случае достаточно одного скрытого слоя для аппроксимации функции нейросетью. Рекомендуемое количество нейронов в скрытом слое рассчитывается с помощью формулы $k = \sqrt{nm}$ (где k – число нейронов в скрытом слое, n – число нейронов во входном слое, m – число нейронов в выходном слое) [14], что дает в данном случае значение

$$k = \sqrt{8 * 1} \approx 3.$$

Добавив в скрытый слой нейрон смещения, получим итоговое количество: $3+1 = 4$ скрытых нейрона.

Количество синапсов (весов) в НС составляет: 32 – от входного слоя к скрытому, и 4 – от скрытого слоя к выходному, то есть всего 36.

В качестве функции активации применяется сигмоидная функция [10], как оптимальная для рассматриваемой задачи (устанавливается эмпирическим путем).

Обучение нейросети

Для обучения НС выбран пакетный режим, который подразумевает настройку весов синапсов для минимизации невязки в сумме по всем элементам обучающей выборки [10]. Целевая оптимизационная функция выглядит следующим образом:

$$\Phi(\bar{w}_1, \bar{w}_2) = \sum_{i=1}^N (f(\sum_{k=1}^4 f(\sum_{j=1}^8 x_i^j * w_1^j) * w_2^k) - J_i)^2 \rightarrow \min, \quad (8)$$

где $f(z) = \frac{1}{1+\exp(-z)}$ – функция активации (сигмоид), \bar{w}_1, \bar{w}_2 – векторы искомых весов соответственно от входного слоя к скрытому и от скрытого к выходному, j – номер нейрона во входном слое, k – номер нейрона в скрытом слое, i – номер элемента обучающей выборки, x_i^j – j -й входной параметр i -го элемента обучающей выборки, N – количество элементов обучающей выборки.

Поскольку целевая функция (8) при большом числе искомых весов может иметь множество стационарных точек, предпочтительно использование стохастических алгоритмов обучения (оптимизации). В данной работе применен генетический алгоритм [15].

В начале обучения НС необходимо сгенерировать гены (значения отдельных весов) для всех особей (различных векторов весов \bar{w}_1 и \bar{w}_2) начальной популяции [16]. Для достаточной разновидности популяции (существенного различия векторов \bar{w}_1 и \bar{w}_2 разных особей) генерация весов должна иметь стохастический характер и обеспечивать хорошее приближение к равномерному распределению [17]. Оптимальный размер популяции подбирается эмпирически, в данной задаче он оказался равным 50 особям.

Для кроссинговера (создания особей на новой итерации из имеющихся членов популяции) использован традиционный способ комбинирования 2-х разных частей особей-родителей со стохастическим порядком их соединения [15]. Выбор особей-родителей осуществлялся методом панмиксии, который в наибольшей степени гарантирует сохранение генетического разнообразия популяции [15]. В качестве метода селекции (отбора наилучших особей-родителей с точки зрения оптимизации целевой функции) использован метод рулетки [16], который хорошо работает на задачах минимизации и довольно прост в реализации. Оптимальная доля мутантов (случайно генерируемых особей на каждой итерации [16]), определяемая эмпирическим путем, задана равной 5%.

Результаты

Поскольку процедура обучения является ресурсоемкой, в рамках данной работы обучение НС произведено не на всей описанной выше обучающей выборке из двух ПФЭ, а на составленной из ее членов случайным образом обучающей выборке из 20 элементов. В качестве контрольной использована выборка из 11 элементов, не входящих в обучающую.

В табл. 1 сопоставлены значения критерия качества на объектах обучающей выборки: слева – посчитанные на обученной НС, справа – фактические (на основе численного решения прямой задачи). В табл. 2 аналогичное сопоставление приведено для объектов контрольной выборки. В графическом виде результаты представлены на рис. 8–10: на обучающей выборке (см. рис. 8), на контрольной выборке (см. рис. 9) и совместный график (см. рис. 10).

Таблица 1

Результаты обучения на объектах обучающей выборки

$J_{\text{расч}}$	$J_{\text{факт}}$
782,564	786,976
343,514	458,428
645,333	788,73
2360,83	2236,83
979,402	994,748
1309,22	1336,78
1931,85	1839,62
1239,34	1224,37
287,337	414,321
930,721	997,023
1181,71	1134,34
2083,16	2137,51
1341,73	1259,32
416,881	452,332
452,939	502,205
862,189	788,397
1496,97	1505,63
2211,54	2145,33
2324,83	2310,63

Таблица 2

Результаты применения НС на объектах контрольной выборки

$J_{\text{расч}}$	$J_{\text{факт}}$
789,366	831,587
813,414	709,53
3378,16	3506,3
3295,74	2767,8
3775,66	3506,22
791,191	830,85
3542,46	3807,57
2080,29	2083,16
1041,67	1341,73
412,003	416,881
592,152	452,939




Рис. 8. Аппроксимация функционала на объектах обучающей выборки




Рис. 9. График качества аппроксимации на контрольной выборке




Рис. 10. Совместный график качества аппроксимации на объектах обучающей и контрольной выборок

Из рис. 8–10 можно увидеть, что и на обучающей выборке, и на контрольной хорошо воспроизводится характер изменения аппроксимируемой функции. Закономерно, что на контрольной выборке не во всех точках получено столь же близкое приближение к значению функционала, как на обучающей. В то же время сохраняется относительное ранжирование значений критерия качества на разных наборах входных параметров, что наиболее важно для решения обратной задачи. Отметим также, что обученная НС корректно работает на контрольной выборке, даже несмотря на то, что диапазон значений функционала на ней шире, чем на обучающей.

Выводы

Полученные результаты показывают, что методы машинного обучения способны успешно заменять численное решение прямых задач для расчета функционала в обратных задачах многофазной фильтрации на его аппроксимацию искусственной нейронной сетью. При этом достаточного качества аппроксимации удастся получить даже на сильно ограниченной по объему обучающей выборке. Что касается количественного оценивания, то более точного результата можно достичь при большем количестве итераций обучающего (генетического) алгоритма и за счет увеличения размера выборки до предложенного двойного полного факторного эксперимента. Ускорить работу алгоритма и повысить точность обучения можно с помощью изменения способа селекции в генетическом алгоритме, добавления генетической встряски, либо добавив в структуру сети больше нейронов в скрытый слой. Таким образом, есть достаточно способов улучшения обучения сети, а по динамике обучения видно, что предложенной структурой и методом обучения НС возможно получить аппроксимацию искомой функции с хорошей точностью. При этом широкие перспективы применения НС в приложении к многофазной фильтрации связаны не только с обратными задачами, но и с оценкой неопределенности прогноза на основе многовариантного решения прямых задач.

Тем не менее, необходимо учитывать, что в рассмотренной постановке НС требует повторной генерации обучающей выборки и переобучения на каждом новом наборе фактических замеренных показателей работы скважины в функционале (5). Эта особенность не позволяет НС показать большую эффективность при реальном решении обратных задач, чем, например, применение методов теории оптимального управления (сопряженных методов) [2, 5]. Поэтому дальнейшие исследования целесообразно направить на формулировку и решение задач машинного обучения в более востребованной для практики постановке.

Статья написана в рамках выполнения государственного задания (тема «Научное обоснование новых экологически чистых технологий разработки месторождений углеводородов в сложных горно-геологических условиях на основе 3D-компьютерных экспериментов», № АААА-А16-116022510270-1).

ЛИТЕРАТУРА

1. Oliver D.S., Reynolds A.C., Liu N. Inverse Theory for Petroleum Reservoir Characterization and History Matching. N.Y.: Cambridge University Press, 2008. 394 p.

2. Закиров Э.С. Трехмерные многофазные задачи прогнозирования, анализа и регулирования разработки месторождений нефти и газа. М.: Изд. дом «Грааль», 2001. 302 с.
3. *Oliver D.S., Chen Y.* Recent progress on reservoir history matching: a review // *Computational Geosciences*. 2011. Vol. 15. P. 185–221.
4. Закиров С.Н., Индрупский И.М., Закиров Э.С., Аникеев Д.П. Новый подход к исследованию скважин и пластов // *Нефт. хоз-во*. 2002. № 6. С. 113–115.
5. Закиров С.Н., Индрупский И.М., Закиров Э.С., Закиров И.С., Абасов М.Т., Фахретдинов Р.Н., Аникеев Д.П., Рощина И.В., Контарев А.А., Северов Я.А., Роцин А.А., Мамедов Э.А., Брадулина О.В., Лукманов А.Р. Новые принципы и технологии разработки месторождений нефти и газа. Ч. 2. М.-Ижевск: Ин-т компьютер. исслед.; НИЦ «Регулярная и хаотическая динамика», 2009. 484 с.
6. Индрупский И.М., Закиров Э.С., Аникеев Д.П., Ипатов А.И., Фахретдинов Р.Н., Гуляев Д.Н., Ключан И.П. Определение относительных фазовых проницаемостей в скважинных условиях. // *Нефт. хоз-во*. 2008. № 5. С. 39–42.
7. Закиров С.Н., Индрупский И.М., Закиров Э.С., Аникеев Д.П., Васильев И.В., Северинов Э.В., Гайдуков Л.А., Родионов А.Е., Лачугин Д.С., Цаган-Манджиев Т.Н. Проведение исследований по определению функций ОФП для нефти и воды в пластовых условиях [Электронный ресурс] // Труды Российской нефтегазовой технической конференции SPE. М., 16–18 октября 2012. Статья SPE-162011-RU. – Режим доступа: www.onepetro.org (Дата обращения 09.07.2018).
8. Закиров Э.С., Индрупский И.М., Васильев И.В., Аникеев Д.П., Цаган-Манджиев Т.Н., Родионов А.Е., Лачугин Д.С., Афанасьев В.С., Афанасьев С.В., Антонович А.А. Проведение комплексных исследований по оценке относительных фазовых проницаемостей для нефти и воды и коэффициента вытеснения в условиях аномально низкой приемистости пласта (часть 1) // *Нефт. хоз-во*. 2016. № 9. С. 56–60.
9. Закиров Э.С., Индрупский И.М., Васильев И.В., Аникеев Д.П., Цаган-Манджиев Т.Н., Родионов А.Е., Лачугин Д.С., Афанасьев В.С., Афанасьев С.В., Антонович А.А. Проведение комплексных исследований по оценке относительных фазовых проницаемостей для нефти и воды и коэффициента вытеснения в условиях аномально низкой приемистости пласта (часть 2) // *Нефт. хоз-во*. 2017. № 10. С. 90–93.

10. Дьяконов А.Г. Анализ данных, обучение по прецедентам, логические игры, системы WEKA, RapidMiner и MatLab: Учеб. пособие. М.: Изд. отдел фак-та ВМК МГУ им. М.В. Ломоносова, 2010. 278 с.
11. Уоссермен Ф. Нейрокомпьютерная техника: теория и практика. М.: Мир, 1992. 184 с.
12. Закиров С.Н., Закиров Э.С., Индрунский И.М., Левченко В.С., Брадулина О.В., Цаган-Манджиев Т.Н. Вертикальное и 3D гидропрослушивание продуктивных пластов // Новые технологии освоения и разработки трудноизвлекаемых запасов нефти и газа и повышения нефтегазоотдачи: Сб. тр. VII Междунар. технологич. симпозиума. М., 2008. С. 49–63.
13. Ахназарова С.Л., Кафаров В.В. Методы оптимизации эксперимента в химической технологии. М.: Высш. шк., 1985. 327 с.
14. Выбор параметров нейронной сети [Электронный ресурс] // Режим доступа: http://mei06.narod.ru/sem7/iis/shpora/page2_9.htm (Дата обращения 18.05.2018).
15. Mitchell M. An Introduction to Genetic Algorithms. Cambridge, MA: The MIT Press, 1996. 270 p.
16. Панченко Т.В. Генетические алгоритмы: учебно-методич. пособие. Астрахань: Астраханский университет, 2007. 87 с.
17. Попов В.А. Теория вероятностей. Часть 2. Случайные величины: Учеб. пособие. Казань: Казанский университет, 2013. 45 с.