

УДК 004.89:622.276

И.В. Евсюткин, Н.Г. Марков

Управление геолого-техническими мероприятиями на месторождениях нефти и газа с использованием искусственных нейронных сетей

Своевременный выбор скважин-кандидатов на проведение геолого-технических мероприятий (ГТМ) и выбор конкретных ГТМ для таких скважин являются актуальными задачами для нефтегазодобывающих компаний. Сегодня решение этих задач осуществляется преимущественно за счёт большого опыта и интуиции специалиста-геолога. Более того, процесс решения требует серьёзных затрат времени специалистов и не исключает ошибочных результатов, связанных с человеческим фактором. Поэтому актуальным направлением исследований являются разработка и внедрение новых интеллектуальных методов анализа геологических и технологических данных при управлении ГТМ. В статье предложено при решении задач управления ГТМ использовать глубокие искусственные нейронные сети прямого распространения. Приведены результаты комплексных исследований эффективности таких нейронных сетей при управлении ГТМ, показавшие перспективность этого метода интеллектуального анализа данных при автоматизации нефтегазодобывающего производства.

Ключевые слова: геолого-технические мероприятия на месторождениях нефти и газа, автоматизация производства, интеллектуальный анализ данных, искусственные нейронные сети.

doi: 10.21293/1818-0442-2020-23-1-62-69

Бурения новых скважин на эксплуатируемых месторождениях являются трудоемкими и дорогостоящими проектами, поэтому в качестве альтернативного подхода большинство нефтегазодобывающих предприятий использует методы интенсификации добычи углеводородного сырья (УВС) из существующих скважин. Среди них особый интерес представляют геолого-технические мероприятия (ГТМ), повышающие интенсивность добычи УВС.

Управление ГТМ требует значительных трудовых и временных затрат квалифицированных специалистов-геологов предприятия, которые на сегодняшний день практически вручную анализируют большие объемы разнородных геологических и технологических данных по фонду скважин, что способствует увеличению вероятности возникновения ошибок вследствие человеческого фактора [1]. Всё это указывает на актуальность разработки методов и алгоритмов высокоавтоматизированного управления ГТМ в условиях больших объемов постоянно обновляющихся на промыслах данных.

В настоящее время всё более актуальной становится концепция интеллектуальных месторождений [2]. Неотъемлемой её частью является разработка методов интеллектуального анализа данных (ИАД) для поддержки принятия решений при управлении фондом скважин, в том числе при управлении ГТМ.

Целью данной работы является исследование эффективности глубоких искусственных нейронных сетей (ИНС) прямого распространения применительно к задачам управления ГТМ.

Интеллектуальные методы анализа данных при управлении фондом скважин

При разработке месторождений нефти и газа основным объектом управления является фонд скважин, позволяющий тем или иным способом извлекать УВС из продуктивных пластов месторождения. Сегодня управление фондом скважин добыва-

ющего предприятия – это управление совокупностью весьма сложных бизнес-процессов, начиная с планирования уровней добычи УВС, мониторинга состояния скважин и продуктивных пластов, интенсификации процессов добычи УВС и заканчивая организацией и проведением работ по текущему и капитальному ремонту скважин [3].

Среди процессов интенсификации добычи особое место занимают ГТМ. Они являются управляющими воздействиями на элементы объекта управления – скважины фонда и продуктивные пласты. Решение о проведении ГТМ принимает субъект управления – специалисты различных служб промысла, в первую очередь, геологической. Принятые ими решения о ГТМ на той или иной скважине реализуют бригады текущего и капитального ремонта скважин или при проведении сложного ГТМ специалисты подрядной организации. Важным реализуемым в системе управления фондом скважин процессом является оценка эффективности проведённых ГТМ. Такая оценка опирается на решение задачи прогноза дебитов УВС с использованием методов ИАД. Оценка эффективности позволяет сформировать обратные связи и, если это требуется, корректировать управляющие воздействия на скважины или пласты [4]. Например, довольно часто выполняется на одном и том же блоке месторождения многократный гидроразрыв пласта (ГРП) – один из перспективных методов ГТМ [5].

С другой стороны, управление ГТМ требует решения ряда сложноформализуемых задач. В первую очередь, к ним относятся задача выбора скважин-кандидатов для ГТМ и задача определения вида ГТМ для таких скважин. Для решения этих задач требуются значительные трудовые и временные затраты квалифицированных специалистов. Это ещё раз подчёркивает необходимость использования в контуре управления методов ИАД как методов

поддержки принятия решений субъектом управления в реализации таких сложноформализуемых задач.

В статье [5] приведены результаты исследования применения ИНС для прогноза параметров работы скважин после проведения ГРП на крупных месторождениях УВС. Точность результатов оказалась невысокой для последующего практического применения этих ИНС.

В работе [6] был проведён анализ операций по выравниванию профиля приёмистости для нагнетательных скважин, а также оценено влияние геолого-геофизических характеристик и технологических показателей работы скважин на результат с точки зрения прироста добычи нефти вследствие уменьшения обводнённости УВС. При этом предложено использовать ИНС для предсказания технологической эффективности от выравнивания профиля приёмистости скважин. Показано, что точность полученной модели сопоставима с таковой в методе гидродинамического моделирования пластов, но скорость работы ИНС оказалась гораздо выше.

Другим классом методов ИАД, который исследовался на предмет использования в управлении фондом скважин нефтегазодобывающих предприятий, является класс методов кластеризации данных. Так, в работе [7] применялся кластерный анализ для разделения фонда скважин месторождения на кластеры (группы) в зависимости от приоритетности проведения ГТМ, затем на подкластеры – по типу ГТМ для каждой скважины.

Основными недостатками примененного подхода являются использование для анализа только геологических данных и простейший алгоритм кластеризации, который на одном и том же наборе исходных данных может показывать различные результаты, чувствителен к шумам и требует априорного задания количества кластеров.

В статьях [8–11] приводятся первые результаты исследований при решении задачи выбора скважин-кандидатов для ГТМ с использованием ещё одного метода ИАД – метода нечёткой логики. К сожалению, эти результаты имеют невысокую точность.

Таким образом, с помощью методов ИАД получены первые обнадеживающие результаты, но на сегодняшний день они не обладают приемлемой для практиков точностью. Поэтому необходимы дальнейшие исследования новых методов ИАД применительно к задаче выбора скважин-кандидатов для ГТМ и выбора типа мероприятий на скважинах-кандидатах.

В развитие описанных выше исследований в данной работе предложено при управлении ГТМ использовать один из перспективных методов ИАД – глубокие нейронные сети прямого распространения [12]. Рассмотрены особенности подготовки обучающей и тестовой выборки для таких ИНС на основе больших массивов геологических и технологических данных на эксплуатируемом месторождении и исследована эффективность этих ИНС при решении задач управления ГТМ.

Предварительная обработка больших данных перед обучением ИНС

Большие объёмы разнородных технологических и геологических данных с датчиков и результаты ручного ввода обычно аккумулируются в базах данных (БД) информационных систем предприятий по добыче УВС. Для датчиков характерны сбои, ручной ввод также может давать ошибки в данных: опечатки, несоблюдение единиц измерений и их порядков и т.д. В результате БД содержат частично ошибочную, пропущенную и искажённую информацию, дублированные и противоречивые данные [13, 14].

При решении задач интенсификации добычи УВС важно, чтобы исходные технологические данные по фонду скважин и геологические данные по продуктивным пластам месторождения были актуальны и не содержали пропусков и ошибок. Это особенно важно для дальнейшего интеллектуального анализа таких данных и принятия решений при управлении ГТМ. Однако в реальности на промыслах другая картина. В БД информационных систем для управления производством, в которых за многие годы эксплуатации месторождения накопился огромный объём данных, довольно много пропущенных данных и ошибок ручного ввода.

Многие методы анализа данных, в том числе интеллектуальные, очень чувствительны к пропускам и выбросам в данных. Некоторые из них в таких случаях следует применять с осторожностью.

В качестве наборов данных для обучения и тестирования ИНС были выбраны значения указанных ниже параметров для каждого комплекса «скважина–пласт». Использовались следующие геологические и технологические параметры: дебит нефти Q_n , т; дебит газа Q_g , тыс. м³; дебит жидкости $Q_{ж}$, м³; дебит воды Q_w , т; давление забойное $P_{заб}$, атм; давление буферное $P_{буф}$, атм; давление затрубное $P_{зат}$, атм; температура на устье скважины T_y , °С; давление пластовое $P_{пл}$, атм; пластовая температура $T_{пл}$, °С; обводнённость W , %; эффективная мощность пласта H , м; газовый фактор B ; диаметр штуцера D , мм. К сожалению, не для всех этих параметров имеется возможность извлечь из БД достаточный объём данных для обучения ИНС.

Ручная инспекция данных сложна ввиду чрезвычайно больших объёмов данных, например, некоторые значения технологических параметров скважин поступают в БД каждые 15 мин, и даже за небольшой промежуток времени в БД накапливается большой объём данных. Более того, просмотр данных специалистом по-прежнему не страшает от новых ошибок. Поэтому перспективным решением является использование специальных программных средств, реализующих методы и правила обнаружения и исправления ошибок в таких данных.

Известно, что каждый технологический параметр скважины или геологический параметр продуктивного пласта месторождения должен находиться в определённом диапазоне значений в зависимости от месторождения и условий его эксплуата-

ции [15]. Тогда, учитывая допустимые диапазоны значений параметров, можно определить ошибочные значения этих параметров, а для их исправления использовать различные зависимости, например, закон Дарси или метод интерполяции исправляемых значений по соседним корректным значениям параметра. Ряд параметров, в первую очередь геологических, в силу своей природы не может изменяться резко. Так, например, эффективная мощность продуктивного пласта может считаться постоянной в течение длительного времени (обычно до года). Тогда в результатах ручного ввода значений таких параметров легко распознать ошибку порядка числа и автоматически её исправить.

Учитывая это, а также ряд особенностей дублируемых записей в БД технологических и геологических параметров, нами были созданы соответствующие программные средства, реализующие различные методы и алгоритмы обнаружения и исправления ошибок в исходных для последующего анализа данных [16]. Для извлечения информации из БД была создана хранимая процедура на языке SQL в СУБД Microsoft SQL Server. Результаты применения созданных программных средств и хранимой процедуры представляются в БД в виде совокупности строк, очищенных и скорректированных, упорядоченных по кустам скважин и отдельным скважинам, по времени измерения каждого параметра из набора и дате проведения каждого ГТМ. Например, строка содержит название куста, номер скважины и дату ввода её в эксплуатацию; название ГТМ, дату его начала и окончания; параметр, его значение и дату измерения.

Задачи классификации скважин и типов ГТМ с использованием ИНС

Во-первых, с целью управления ГТМ ставилась и решалась задача бинарной классификации всех добывающих скважин фонда с помощью глубоких ИНС прямого распространения. В первый класс должны попасть все скважины, которые занесены в БД и были выбраны специалистами-геологами для проведения определённого типа (вида) ГТМ – класс «скважин-кандидатов для ГТМ». Основанный на опыте и интуиции ручной выбор специалистами-геологами скважин-кандидатов для ГТМ считался эталоном при формировании обучающей выборки, если после проведённого ГТМ произошло существенное увеличение дебита скважины.

Во второй класс скважин должны входить все остальные скважины (класс «скважин не для ГТМ»), на которых в момент анализа по той или иной причине ГТМ проводить не следовало. Например, высокодебитные скважины, дающие основной объём добычи УВС на месторождении. Даже небольшая их остановка (для каких-либо работ или исследований) существенно снизит общий уровень добычи УВС на имеющемся фонде скважин. По сути, это задача бинарной классификации, решаемая с помощью ИНС.

Другой задачей управления ГТМ являлась также задача разделения ГТМ на классы и выбора клас-

са (типа) ГТМ для каждой скважины-кандидата. Среди ГТМ выделено четыре класса (типа) мероприятий, обычно примерно в одинаковых пропорциях, проводимых на скважинах: ремонтно-изоляционные работы (РИР) – замена насосно-компрессорных труб, ликвидация межколонных давлений и перетоков; использование электроцентробежных насосов (ЭЦН) – перевод скважин на механизированный способ добычи, спуск ЭЦН, смена ЭЦН; ГРП; прочие мероприятия – ремонт наземного оборудования скважин, смена фонтанной арматуры или пакеров и т.п.

При решении многих задач нет заранее определённых критериев выбора гиперпараметров и архитектуры ИНС. Таким образом, по сути необходимо было провести экспериментальный поиск оптимальных архитектуры и гиперпараметров ИНС для решения поставленных задач классификации скважин и ГТМ.

Число скрытых слоёв ИНС прямого распространения выбиралось равным 2–20. Исследовалось также применение различных функций активации (Sigmoid, TanH, ReLU) и алгоритмов оптимизации при обучении ИНС (SGD, Adam, AdaGrad, AdaDelta), дающих лучшую сходимость при обучении [17]. Изменялась также скорость обучения: 0,2; 0,1; 0,05; 0,01; 0,005; 0,001. Также использовался слой Dropout с различными вероятностями [18].

Обучающая выборка формировалась на основе баз данных технологических и геологических параметров одного из нефтегазоконденсатных месторождений Томской области. Фонд скважин месторождения имеет 142 добывающие скважины, на которых было проведено 436 различных ГТМ за 6 лет.

По данным ряда геологических служб добывающих предприятий известно, что планирование ГТМ происходит не ранее чем за 4 месяца до его проведения. Более того, нет той чёткой границы, когда происходит переход скважины из одного класса в другой класс (из класса рентабельных в класс нерентабельных и требующих ГТМ). Чаще всего это происходит в процессе её эксплуатации от одного проведённого ГТМ до другого путём постепенного изменения значений параметров до критических. Поэтому средний интервал времени между моментами времени проведения соседних ГТМ на скважине разумно считать «сомнительным для принятия решения о необходимости ГТМ» и исключить его из рассмотрения. В общем случае такой интервал не симметричен относительно середины интервала времени эксплуатации скважины между выполненными на ней ГТМ. Экспериментально было установлено, что «сомнительный» интервал времени может составлять до 30% от интервалов времени между ГТМ. Это было учтено при формировании обучающей выборки для ИНС и оценке ее достаточного объёма.

Фонд скважин месторождения часто имеет относительно небольшое количество добывающих скважин, особенно если это месторождение эксплуатируется не так давно. Ещё меньше в таком фонде

тех скважин, которые подвергаются ГТМ в выбранный период времени. Учитывая это, предложено использовать аугментацию данных – методику создания дополнительных обучающих данных из имеющихся данных. Применялся один из основных методов аугментации – добавление к ряду значений вышеперечисленных параметров исходной обучающей выборки случайного шума [19].

Значения различных параметров скважин и продуктивных пластов измеряются в разных диапазонах, и для того чтобы каждый параметр оказывал влияние на конечный результат в экспериментах, осуществлялась нормализация данных [20]. Значения по каждому параметру были нормированы так, чтобы они находились в диапазоне [0, 1].

При исследовании важно понять, какое сочетание геологических и (или) технологических параметров содержит наиболее существенные признаки, которые может извлечь ИНС для решения поставленных задач классификации. Формировались следующие обучающие и тестовые наборы параметров, подаваемых на вход ИНС.

– Набор № 1 – все измеряемые параметры скважин и продуктивных пластов: $Q_n; Q_g; Q_j; Q_v; P_{заб}; P_{буф}; P_{зат}; T_y; D; P_{пл}; T_{пл}; W; H; B$.

– Набор № 2 – все технологические параметры скважин: $Q_n; Q_g; Q_j; Q_v; P_{заб}; P_{буф}; P_{зат}; T_y; B$.

– Набор № 3 – параметры дебитов скважин: $Q_n; Q_g; Q_j; Q_v$.

– Набор № 4 – технологические параметры скважин (без дебитов): $P_{заб}; P_{буф}; P_{зат}; T_y; B$.

– Набор № 5 – параметры дебитов скважин и параметры продуктивных пластов: $Q_n; Q_g; Q_j; Q_v; P_{пл}; T_{пл}$.

– Значения параметров в общем случае измеряются в разное время для каждой конкретной скважины. Чтобы получить вектор всех значений на определённый момент времени, необходимо было интерполировать значения некоторых параметров по соседним имеющимся значениям.

Число обучающих и тестовых примеров, включая данные, полученные за счёт аугментации, составляет 2016 пар «признаки – метки» для каждого указанного выше обучающего и тестового набора. Объём обучающей выборки составляет 80% от общего используемого объёма данных набора. Точность классификации оценивалась для обучающей выборки и для тестовой выборки, составляющей 20% этого объёма данных. Под точностью классификации понимается отношение скважин, правильно отнесённых к заранее известному классу, к общему числу анализируемых скважин в обучающей и тестовой выборках (в процентах). Аналогично вычислялась точность классификации при выборе типа ГТМ.

Для программной реализации ИНС различной архитектуры и задания гиперпараметров ИНС использовалась библиотека Microsoft CNTK, имеющая ряд преимуществ перед другими библиотеками [21]. Схема архитектуры ИНС, приведённая в качестве примера, представлена на рис. 1. Она включает в

себя входной слой, куда подаются значения параметров из того или иного обучающего или тестового набора из пяти перечисленных, совокупность скрытых слоёв (показаны 3 слоя с функцией активации TanH) и выходной слой Softmax. Для предотвращения переобучения перед выходным слоем в ИНС использовался слой Dropout. Из рис. 1 видно, что ИНС в принципе позволяет решать одновременно обе задачи классификации. То есть в случае выбора скважины-кандидата для ГТМ на выходе нейросети имеется выбранный для неё тип ГТМ.



Рис. 1. Схема архитектуры ИНС

Для оценки соответствия используемым для обучения данным каждой из исследуемых архитектур ИНС с её гиперпараметрами применялась технология кроссвалидации. Использовался метод K-блоков, причем $K = 5$. Это означает, что все вычисленные в ходе исследований итоговые значения точности классификации скважин и типов ГТМ являются результатом усреднения по пяти значениям точности, полученным в ходе обучения и тестирования.

Результаты экспериментов и их анализ

В таблице приведены в качестве примера результаты экспериментов с ИНС различной архитектуры для набора № 2 при решении задачи классификации скважин-кандидатов для ГТМ. В экспериментах использованы четыре варианта алгоритмов оптимизации при обучении ИНС и для каждого из них – три варианта наиболее известных функций активации. Аналогичные эксперименты были проведены для наборов № 1, 3, 4 и 5 и результаты сведены в соответствующие четыре таблицы.

На рис. 2 приведены взятые из таблиц все лучшие результаты по точности классификации скважин для всех пяти наборов параметров в случае тестовых выборок. Они получены с помощью оптимизационных алгоритмов обучения Adam или SGD и функций активации TanH или ReLU.

Проанализируем полученные результаты. Видно, что основным фактором, влияющим на точность классификации, является различие архитектур ИНС, в первую очередь, по числу скрытых слоёв.

Функция активации Sigmoid для всех алгоритмов обучения и алгоритм оптимизации при обучении AdaDelta для всех функций активации не позволили получить высокую точность классификации скважин вследствие плохой обучаемости ИНС.

Результаты классификации скважин с использованием ИНС в случае набора № 2

Алгоритм обучения	Функция активации	Выборка	Точность классификации скважин, %											
			Число слоёв											
			2	3	4	5	6	7	8	9	10	15	20	
SGD	Sigmoid	Обучающая	65,327	52,874	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000
		Тестовая	64,205	52,092	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000
	TanH	Обучающая	93,416	98,250	99,228	97,115	99,332	98,870	97,220	99,590	96,497	99,640	91,298	
		Тестовая	92,594	96,722	97,734	95,910	98,359	97,730	95,268	97,326	95,702	97,334	89,337	
	ReLU	Обучающая	94,853	98,148	98,765	98,970	99,127	97,323	99,333	99,024	98,095	98,971	94,539	
		Тестовая	93,019	96,305	97,134	97,334	97,947	96,709	97,534	97,938	97,746	95,893	92,827	
AdaGrad	Sigmoid	Обучающая	53,232	52,423	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	
		Тестовая	52,708	52,245	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	
	TanH	Обучающая	86,005	93,467	97,839	99,074	99,537	99,280	98,662	99,332	99,536	99,614	99,076	
		Тестовая	85,604	93,414	96,913	97,742	96,702	96,913	96,918	96,922	97,334	97,118	96,084	
	ReLU	Обучающая	49,692	47,737	56,995	51,594	50,566	46,912	50,051	50,671	46,135	52,881	50,000	
		Тестовая	49,800	47,938	57,198	51,641	50,629	47,326	50,208	51,433	46,327	53,291	50,000	
AdaDelta	Sigmoid	Обучающая	50,103	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	
		Тестовая	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	50,000	
	TanH	Обучающая	56,168	63,271	52,470	51,851	48,463	58,180	57,716	59,722	55,194	64,403	63,323	
		Тестовая	55,761	62,751	52,462	52,270	48,963	58,019	57,194	59,881	54,736	64,392	63,376	
	ReLU	Обучающая	52,830	62,447	61,058	61,266	66,716	60,495	60,805	61,575	58,537	70,113	75,670	
		Тестовая	52,474	61,505	60,697	61,101	66,471	60,068	60,276	61,922	58,027	69,116	74,881	
Adam	Sigmoid	Обучающая	84,158	89,760	96,039	82,665	81,662	73,243	71,504	55,132	51,751	50,825	50,000	
		Тестовая	83,529	89,107	93,831	79,821	80,672	70,391	69,575	54,362	51,637	50,816	50,000	
	TanH	Обучающая	99,794	99,640	98,508	99,383	99,846	99,537	99,279	98,256	96,393	51,388	51,540	
		Тестовая	97,126	98,563	96,922	97,942	98,767	97,530	97,334	96,909	95,710	51,442	51,247	
	ReLU	Обучающая	99,486	97,889	99,332	99,281	99,486	99,332	99,538	99,589	89,639	59,333	59,227	
		Тестовая	98,146	96,298	97,326	97,126	97,326	97,942	98,159	98,567	88,163	59,583	59,184	




Рис. 2. Лучшие результаты по точности классификации скважин на тестовых выборках

Весьма низкие результаты наблюдаются при использовании в ИНС 2 или 3 скрытых слоёв для всех алгоритмов оптимизации, кроме алгоритма Adam. По-видимому, это связано с тем, что число извлекаемых в этих случаях признаков скважины для отнесения ее к тому или иному классу не соответствует сложности задачи. Для числа скрытых слоёв более 10 для этих же алгоритмов оптимизации

и функций активации результаты также невысоки. Из рис. 2 следует, что наилучшая точность для разного числа скрытых слоёв ИНС достигнута для набора № 1, а наихудшая – для набора № 3.

На практике для столь серьезного по финансовым затратам мероприятия, как остановка скважины и выполнение на ней того или иного ГТМ, важно иметь как можно большую точность классификации. Поэтому средняя точность классификации при обучении ИНС более 99% и средняя точность при её тестировании более 98% были выбраны как приемлемые для практического использования (см. таблицу, значения указаны жирным шрифтом). Выше таких пороговых значений точности находятся результаты, полученные на наборах № 1 и 2 с помощью оптимизационных алгоритмов Adam и SGD и функций активации TanH и ReLU. Остальные результаты не представляют практический интерес.

Все результаты по точности классификации скважин, приемлемые для практического использования, сравнивались по критерию Краскала-Уоллиса. Показано, что отличия в результатах при выборочных флуктуациях не являются существенными при уровне значимости, равном 0,05.

Так как разница в точности классификации скважин для указанных архитектур ИНС незначительна, на некоторых нефтегазодобывающих предприятиях могут отдать предпочтение наиболее простым моделям ИНС с точки зрения их архитектуры и числа параметров на входе. Например, архитектуре с тремя или даже с двумя скрытыми слоями и функцией активации TanH или ReLU. При этом на входе ИНС будет набор № 2 параметров, а обучение нейросети ведётся по алгоритму Adam. Это позволит

снизить требования к вычислительным ресурсам, необходимым для анализа технологических и геологических данных с помощью ИНС, а также минимизировать перечень параметров на входе нейросети и соответственно объем предварительной подготовки к анализу значений таких параметров.

Этот пример показывает, что полученные результаты исследования могут быть востребованы для разработки методики использования сложного аппарата глубоких ИНС при управлении ГТМ.

В экспериментах по определению точности классификации при выборе типа (класса) ГТМ на выявленных скважинах-кандидатах для ГТМ использовались архитектуры и гиперпараметры ИНС, а также обучающие и тестовые наборы данных, давшие наилучшие результаты по точности классификации скважин. В итоге для ИНС с 9 скрытыми слоями для алгоритма Adam и функции активации TanH в случае набора № 2 получена наилучшая точность классификации типов ГТМ при тестировании – 85%. Знание типа ГТМ позволит специалисту-геологу сузить область рассмотрения потенциально возможных ГТМ для скважины-кандидата и тем самым окажет ему поддержку в принятии решения по выбору ГТМ.

Заключение

Сегодня очевидно, что интеллектуальные технологии – главный фактор обеспечения оптимальных управленческих решений при эксплуатации фондов скважин месторождений УВС, в том числе при управлении ГТМ на этих фондах.

Проведены исследования эффективности глубоких ИНС прямого распространения при решении задач классификации при выборе скважин-кандидатов для проведения ГТМ и при выборе типа ГТМ для таких скважин. Наилучшие и практически приемлемые результаты по точности выбора скважин-кандидатов для ГТМ (более 98% на тестовых выборках) были достигнуты при подаче на вход ИНС полного набора всех измеряемых технологических и геологических параметров или набора всех технологических параметров скважины. При этом обучение ИНС велось с использованием оптимизационных алгоритмов Adam и SGD и функций активации ReLU и TanH. Наилучшая точность классификации типов ГТМ для скважин-кандидатов составила 85% на тестовых выборках.

Отметим, что полученные результаты исследований эффективности глубоких ИНС позволят создать методику использования ИНС при управлении ГТМ на месторождениях нефти и газа.

Литература

1. Марков Н.Г. Информационно-управляющие системы для газодобывающего производства. – Томск: Изд-во Том. политехн. ун-а, 2016. – 261 с.
2. Барбер Э. Оптимизация добычи: от продуктивного пласта до пункта подготовки нефти и газа / Э. Барбер, М.Е. Шиппен, С. Баруа // Нефтегазовое обозрение. – 2008. – Т. 19, № 4. – С. 22–37.

3. Evsyutkin I. Intellectual information system for management of geological and technical arrangements during oil field exploitation / I. Evsyutkin, N. Markov // Journal of Physics: Conference Series. – 2017. – Vol. 803: Information Technologies in Business and Industry (ITBI2016): International Conference, 21–26 September 2016, Tomsk, Russian Federation. – [012093, 6 p].

4. Березина А.А. Экономическая концепция нефтегазового «интеллектуального» месторождения / А.А. Березина, А.Е. Череповицын // Нефтяное хозяйство. – 2014. – № 14. – С. 14–15.

5. Редикульцев С.А. Использование метода нейронных сетей для прогноза параметров работы скважин после проведения ГРП / С.А. Редикульцев, А.В. Липлянин, А.О. Палий // Бурение, разработка, добыча. – 2010. – Т. 5, № 1. – С. 33–37.

6. Келлер Ю.А. Разработка искусственных нейронных сетей для предсказания технологической эффективности от выравнивания профиля приёмистости // Изв. Том. политехн. ун-та. Сер.: Информационные технологии. – 2014. – Т. 325, № 5. – С. 60–65.

7. Келлер Ю.А. Применение кластеризации данных на основе самоорганизующихся карт Кохонена при подборе скважин-кандидатов для методов увеличения нефтеотдачи // Управление, вычислительная техника и информатика: Вестник Том. гос. ун-та. – 2014. – Т. 28, № 3. – С. 32–37.

8. Кашапов А. Применение теории нечётких множеств для поиска скважин-кандидатов на проведение геолого-технических мероприятий // SPE International, Society of Petroleum Engineers [Электронный ресурс]. – Режим доступа: <https://www.onepetro.org/conference-paper/SPE-176744-RU> (дата обращения: 15.01.2020).

9. Галиуллин М.М. Методика выбора скважин-кандидатов для интенсификации добычи с использованием математического аппарата нечёткой логики / М.М. Галиуллин, П.В. Зимин, В.В. Васильев // Нефтяное хозяйство. – 2011. – № 6. – С. 120–123.

10. Odedele T.O. Oil Well Performance Diagnosis System Using Fuzzy Logic Inference Models / T.O. Odedele, H.D. Ibrahim // Proceedings of The World Congress on Engineering. – 2014. – P. 80–85.

11. Okwu M.O. A review of fuzzy logic applications in petroleum exploration, production and distribution operations / M.O. Okwu, N.A. Nwachukwu // Journal of Petroleum Exploration and Production Technology. – 2018. – Vol. 9. – P. 1555–1568.

12. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУиГУ. Сер.: Вычислительная математика и информатика. – 2017. – Т. 6, № 3. – С. 28–59.

13. Azeroual O. Data Quality Measures and Data Cleansing for Research Information Systems / O. Azeroual, G. Saake, M. Abuosba // Journal of Digital Information Management. – 2018. – Vol. 16, No. 1. – P. 12–16.

14. Kofi Sarpong Adu-Manu A Review of Data Cleansing Concepts Achievable Goals and Limitations / Kofi Sarpong Adu-Manu, John Kingsley Arthur // International Journal of Computer Applications. – 2013. – Vol. 7, No. 76. – P. 19–22.

15. Евсюткин И.В. Веб-сервис обнаружения и корректировки ошибок в данных на промыслах нефтегазодобывающих компаний / И.В. Евсюткин, Н.Г. Марков / Сб. науч. тр. XVI Междунар. науч.-практ. конф. студентов, аспирантов, молодых учёных «Молодёжь и современные информационные технологии», Томск, 3–7 декабря 2018 г. – Томск: Изд-во Том. политехн. ун-та, 2019. – С. 231–232.

16. Коршак А.А. Основы нефтегазового дела: учебник для вузов. – 3-е изд., испр. и доп. / А.А. Коршак,

А.М. Шаммазов. – Уфа.: ООО «ДизайнПолиграфСервис», 2005. – 528 с.

17. Dropout: A Simple Way to Prevent Neural Networks from overfitting / Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov // *Journal of Machine Learning Research*. – 2014. – Vol. 15. – P. 1929–1958.

18. Darío Baptista Performance comparison of ANN training algorithms for classification / Darío Baptista, Sandy Rodrigues, F. Morgado-Dias // *Conference: Intelligent Signal Processing (WISP), 2013 IEEE 8th International Symposium*. – 2013. – P. 115–120.

19. Khandakar M. Times-series data augmentation and deep learning for construction equipment activity recognition / M. Rashid Khandakar, Joseph Louis // *Advanced Engineering Informatics*. – 2019. – Vol. 42. – Article 100935.

20. Han J. *Data Mining: Concepts and Techniques*, 3rd Edition / J. Han, M. Kamber, J. Pei. – Elsevier Science, 2011. – 744 p.

21. Shaohuai Shi Benchmarking State-of-the-Art Deep Learning Software Tools / Shaohuai Shi, Qiang Wang, Pengfei Xu, Xiaowen Chu // *arXiv:1608.07249v7 [cs. DC]* 17 Feb 2017. – URL: <https://arxiv.org/pdf/1608.07249.pdf> (дата обращения: 15.01.2020).

Евсюткин Иван Викторович

Аспирант Отделения информационных технологий (ОИТ) Инженерной школы информационных технологий и робототехники (ИШИТР)

Национального исследовательского Томского политехнического университета (НИ ТПУ) Ленина пр-т, д. 30, г. Томск, Россия, 634050

Тел.: +7-923-425-12-09

Эл. почта: ive1@tpu.ru

Марков Николай Григорьевич

Д-р техн. наук, профессор ОИТ ИШИТР НИ ТПУ Ленина пр-т, д. 30, г. Томск, Россия, 634050

Тел.: +7 (382-2) 70-16-09

Эл. почта: markovng@tpu.ru

Evsyutkin I.V., Markov N.G.

Management of geological and technical arrangements on oil-and-gas fields with the use of artificial neural networks

The timely selection of the wells to carry out the geological and technical arrangements (GTAs) and the selection of definite GTAs for such wells are crucial tasks for oil-and-gas extraction companies. Nowadays, these tasks are solved mainly using the wide experience and intuition of the specialist-geologist. Moreover, the decision process demands serious time contributions from a specialist and does not exclude the incorrect results bound with a human factor. Therefore, the development and deployment of new intellectual methods of the geological and technological data analysis for the management of GTAs are aimed in the research. In the article, the authors propose to use deep feed-forward neural networks when solving GTAs management problems. The results of complex efficiency evaluation for such neuron networks, which showed the potential of this method of intellectual data analysis for the GTAs management, are described.

Keywords: geological and technical arrangements on oil-and-gas fields, automation of the production, the intellectual analysis of data, artificial neural networks.

doi: 10.21293/1818-0442-2020-23-1-62-69

References

1. Markov N.G. *Informatsionno-upravlyayushchiye sistemy dlya gazodobyvayushchego proizvodstva* [Management of information systems for gas production]. Tomsk, Tomsk Polytechnic University Publ., 2016, 261 p. (in Russ.)

2. Barber E., Shippen M.E., Barua S. [Extraction optimization: from productive formation to the point of oil-and-gas preparation]. *Oil and gas review*, 2008, vol. 19, no. 4, pp. 22–37 (in Russ.).

3. Evsyutkin I., Markov N. Intellectual information system for management of geological and technical arrangements during oil field exploitation. *Journal of Physics: Conference Series*, 2017, vol. 803: Information Technologies in Business and Industry (ITBI2016): International Conference, 21–26 September 2016, Tomsk, Russian Federation [012093, 6 p.].

4. Berezina A.A., Cherepovitsyn A.E. [Economic concept of an oil-and-gas “intellectual” field]. *Oil industry*, 2014, no. 14, pp. 14–15 (in Russ.).

5. Redikultsev S.A., Lipyanin A.V., Paliy A.O. [Use of the method of neural networks for the forecast of parameters of work of wells after carrying out hydraulic fracturing of formation]. *Drilling, development, extraction*, 2010, vol. 5, no. 1, pp. 33–37 (in Russ.).

6. Keller Yu.A. [Development of artificial neural networks for the prediction of technological efficiency from conformance control]. *News of Tomsk Polytechnic University, Information technologies*, 2014, vol. 325, no. 5, pp. 60–65 (in Russ.).

7. Keller Yu.A. [Application of clustering of data based on the self-organizing Kohonen's cards at the selection of candidates-wells for methods of oil extraction increase] // *Control, computers, and informatics: News of Tomsk State University*, 2014, vol. 28, no. 3, pp. 32–37 (in Russ.).

8. Kashapov A. [Application of the fuzzy logic theory for the selection of candidates-wells for carrying out geological and technical arrangements]. *SPE International, Society of Petroleum Engineers*, 2015, SPE-176744-RU (in Russ.).

9. Galiullin M.M., Zimin P.V., Vasilyev V.V. [Approach of the selection of candidates-wells for an extraction intensification with the use of fuzzy logic]. *Oil industry*, 2011, no. 6, pp. 120–123 (in Russ.).

10. Odedele T.O., and Ibrahim H.D. Oil Well Performance Diagnosis System Using Fuzzy Logic Inference Models. *Proceedings of The World Congress on Engineering*, 2014, pp. 80–85.

11. Okwu M.O., Nwachukwu A.N. A review of fuzzy logic applications in petroleum exploration, production and distribution operations. *Journal of Petroleum Exploration and Production Technology*, 2018, vol. 9, pp. 1555–1568.

12. Sozykin A.V. [Review of methods for deep neural networks training]. *News of the Southern-Ural State University*, 2017, pp. 28–59 (in Russ.).

13. Azeroual O., Saake G., Abuosba M. Data Quality Measures and Data Cleansing for Research Information Systems. *Journal of Digital Information Management*, 2018, vol. 16, no. 1, pp. 12–16.

14. Kofi Sarpong Adu-Manu, John Kingsley Arthur A Review of Data Cleansing Concepts Achievable Goals and Limitations. *International Journal of Computer Applications*, 2013, vol. 7, no. 76, pp. 19–22.

15. Evsyutkin I.V., Markov N.G. *Veb-servis obnaruzheniya i korrekcirovki oshibok v dannykh na promyslah neftegazodobyvayushchikh kompaniy* [Web-service of detection and correction of errors in the oil-and-gas extraction companies]. *V sbornike nauchnykh trudov XVI Mezhdunarodnoy konferentsii studentov, aspirantov, molodikh uchyonikh «Mo-*

lodyozh I sovremennyye informatsionnie tekhnologii» (Tomsk, 3-7 dekabrya 2018 g) [“Youth and modern information technologies” (Tomsk, 3–7 December 2018). Proc. of the XVI International scientific and practical conference of students, PhD students, young scientists]. Tomsk. Tomsk Polytechnic University Publ, 2019, pp. 231–232 (in Russ.)

16. Korshak A.A., Shammazov A.M. *Osnovy nefte-gazovogo dela. Uchebnik dlya vuzov* [Bases of the oil-and-gas industry: The educational book for higher education institutions]. Ufa. LLC «DizaynPoligrafServis» Publ., 2005, 528 p. (in Russ.)

17. Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov Dropout: A Simple Way to Prevent Neural Networks from overfitting. *Journal of Machine Learning Research*, 2014, vol. 15, pp. 1929–1958.

18. Dario Baptista, Sandy Rodrigues, F. Morgado-Dias Performance comparison of ANN training algorithms for classification. Conference: Intelligent Signal Processing (WISP), 2013 IEEE 8th International Symposium, 2013, pp. 115–120.

19. Khandakar M. Rashid, Joseph Louis Times-series data augmentation and deep learning for construction equipment activity recognition. *Advanced Engineering Informatics*, 2019, vol. 42, Article 100935.

20. Han J., Kamber M., Pei J. *Data Mining: Concepts and Techniques*, 3rd Edition. Elsevier Science, 2011, 744 p.

21. Shaohuai Shi, Qiang Wang, Pengfei Xu, Xiaowen Chu Benchmarking State-of-the-Art Deep Learning Software Tools. arXiv:1608.07249v7 [cs.DC] 17 Feb. 2017. Available at: <https://arxiv.org/pdf/1608.07249.pdf> (Accessed: January 15, 2020).

Ivan V. Evsyutkin

Post graduate student,
Department of Information Technologies,
School of Computer Science & Robotics,
National Research Tomsk Polytechnic University (NI TPU)
30, Lenin pr., Tomsk, Russia, 634050
Phone: +7-923-425-12-09
Email: ivel@tpu.ru

Nikolay G. Markov

Doctor of Engineering Sciences, Professor,
Department of Information Technologies,
School of Computer Science & Robotics, NI TPU
30, Lenin pr., Tomsk, Russia, 634050
Phone: +7 (382-2) 70-16-09
Email: markovng@tpu.ru