

# ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ РЕШЕНИЯ ЗАДАЧ УПРАВЛЕНИЯ ГЕОЛОГО-ТЕХНИЧЕСКИМИ МЕРОПРИЯТИЯМИ

И.В. Евсюткин, Н.Г. Марков  
Томский политехнический университет  
E-mail: pzerag@mail.ru

## Введение

Бурение новых скважин на эксплуатируемых месторождениях являются трудоемкими и дорогостоящими проектами, поэтому в качестве альтернативного подхода большинство нефтегазодобывающих предприятий используют методы интенсификации добычи углеводородного сырья (УВС) из существующих скважин. Среди таких методов особый интерес представляют геолого-технические мероприятия (ГТМ), повышающие интенсивность добычи. Управление ГТМ требует значительных трудовых и временных затрат квалифицированных специалистов предприятия, которые на сегодняшний день практически вручную анализируют большие объемы разнородных геологических и технологических данных, 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 объёмов, 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 искусственных нейронных сетей (ИНС) при управлении ГТМ.

## Решение задач классификации с использованием ИНС

Во-первых, с целью управления ГТМ ставилась и решалась задача бинарной классификации всех добывающих скважин фонда с помощью глубоких ИНС. В первый класс должны попасть все скважины, которые были выбраны специалистами-геологами для проведения определённого типа (вида) ГТМ – класс «скважин-кандидатов для ГТМ». Основанный на опыте и интуиции ручной выбор 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», на которых в момент анализа по той или иной причине ГТМ проводить не следовало. Например, высокодебитные скважины, дающие основной

объём добычи, даже небольшая их остановка (для каких-либо работ или исследований) существенно снизит общий уровень добычи УВС на имеющемся фонде скважин.

Другой задачей управления ГТМ являлась задача разделения ГТМ на классы и выбор класса (типа) ГТМ для каждой скважины-кандидата. Среди ГТМ выделено три класса (типа) мероприятий, примерно в одинаковых пропорциях, проводимых на скважинах: ремонтно-изоляционные работы (замена насосно-компрессорных труб, ликвидация межколонных давлений и перетоков); использование насосов (перевод скважин на механизированный способ добычи, спуск электроцентробежного насоса (ЭЦН), смена ЭЦН); прочие работы: (гидроразрыв пласта, ремонт, смена фонтанной арматуры или пакеров).

Нет заранее определённых критериев выбора гиперпараметров и архитектурных особенностей ИНС при решении любых задач. Таким образом, по сути, проводился экспериментальный поиск оптимальных архитектуры и параметров ИНС для решения поставленных задач классификации скважин и ГТМ.

Число скрытых слоёв ИНС прямого распространения выбиралось равным: 2, 3, 4, 5, 6, 7, 8, 9, 10, 15, 20, 25, 30. Исследовалось также применение различных функций активации (TanH, Sigmoid, ReLU) и алгоритмов оптимизации при обучении ИНС: SGD, MomentumSGD, Adam, AdaGrad, RMSProp, AdaDelta, дающих лучшую сходимость [3]. Изменялась также скорость обучения: 0.2, 0.1, 0.01, 0.05, 0.001, 0.005. Также использовался слой Dropout с различными вероятностями [4].

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

Использовались значения следующих геологических и технологических параметров: дебит нефти  $Q_n$ , т; дебит газа  $Q_r$ , тыс. м<sup>3</sup>; дебит жидкости  $Q_{ж}$ , м<sup>3</sup>; дебит воды  $Q_v$ , т; давление забойное  $P_{заб}$ , атм; давление буферное  $P_{буф}$ , атм; давление затрубное  $P_{зат}$ , атм; температура на устье скважин  $T_y$ , °С; давление пластовое  $P_{пл}$ , атм; пластовая температура  $T_{пл}$ , °С; обводнённость  $W$ , %; эффективная мощность пласта  $H$ , м; газовый фактор  $V$  и диаметр штуцера  $D$ , мм.

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, предлагается использовать аугментацию данных – методику создания дополнительных обучающих данных из имеющихся данных. Применялся один из основных методов аугментации – добавление к ряду значений исходного набора данных некоторого шума [5].

Значения различных параметров скважин измеряются в разных диапазонах, и, для того, чтобы каждый параметр оказывал влияние на конечный результат в экспериментах, осуществлялась нормализация данных [6]. Значения по каждому параметру были нормированы так, чтобы они находились в диапазоне [0, 1].

Формировались следующие обучающие наборы параметров, подаваемых на вход ИНС:

- Набор №1:  $Q_n; Q_r; Q_{ж}; Q_v; P_{заб}; P_{буф}; P_{заг}; T_y; D; P_{пл}; T_{пл}; W; H; V$ .
- Набор №2:  $Q_n; Q_r; Q_{ж}; Q_v; P_{заб}; P_{буф}; P_{заг}; T_y; V$ .
- Набор №3:  $Q_n; Q_r; Q_{ж}; Q_v$ .
- Набор №4:  $P_{заб}; P_{буф}; P_{заг}; T_y; V$ .
- Набор №5:  $Q_n; Q_r; Q_{ж}; Q_v; P_{пл}; T_{пл}$ .

Число обучающих примеров составляет 2016 пар «признаки – метки» для каждого указанного выше обучающего набора, включая данные, полученные за счёт аугментации. Объём обучающей выборки составил 80% от общего используемого объёма данных. Точность классификации оценивалась на основе тестовой выборки, составляющей 20% этого объёма.

Для программной реализации ИНС различной архитектуры и гиперпараметров использовалась библиотека Microsoft CNTK, имеющая ряд преимуществ перед другими библиотеками.

В таблице приведена часть результатов экспериментов при решении задачи классификации скважин-кандидатов для ГТМ. Наибольшую точность (99%) показала ИНС с 6 скрытыми слоями в случае Набора №2.

Таблица. Точность классификации скважин-кандидатов для ГТМ

Число скрытых слоёв	Точность классификации скважин-кандидатов для ГТМ, %						
	2	4	6	8	10	15	20
Набор №1	96	96	96	96	89	96	93
Набор №2	93	98	99	91	86	97	91
Набор №3	60	63	60	61	65	60	56
Набор №4	82	96	89	96	94	87	83
Набор №5	86	94	97	97	97	97	71

Архитектура сети, давшая наилучший результат, включает по 38 нейронов в каждом скрытом слое. Наилучший результат позволила получить функция активации TanH. Для предотвращения переобучения в этой ИНС использовался слой Dropout с вероятностью 30%. Скорость обучения выбиралась равной 0.001. Наиболее высокие результаты получены для оптимизационного алгоритма обучения SGD.

Наивысшая точность выбора типа ГТМ на скважинах-кандидатах для ГТМ составила 92% для ИНС также с шестью скрытыми слоями.

### 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 выбора типа ГТМ для таких скважин. Наилучшие результаты по точности выбора скважин-кандидатов для ГТМ достигнуты с помощью ИНС с 6 скрытыми слоями (точность 99%), при этом наилучшая точность выбора типа ГТМ для скважин-кандидатов составила 92%.

### Список использованных источников

1. Марков Н.Г. Информационно-управляющие системы для газодобывающего производства. - Томск: изд-во ТПУ, 2016. - 261 с.
2. Оптимизация добычи: от продуктивного пласта до пункта подготовки нефти и газа / Э. Барбер, М.Е. Шиппен, С. Баруа [и др.] // Нефтегазовое обозрение. – 2008. – Т. 19. – № 4. – С. 22–37.
3. Baptista D., Rodrigues S., Morgado-Dias F. Performance comparison of ANN training algorithms for classification // Conference: Intelligent Signal Processing (WISP), 2013 IEEE 8th International Symposium. – 2013. – pp. 115-120.
4. Srivastava Nitish, Hinton Geoffrey, Krizhevsky Alex, Sutskever Ilya, Salakhutdinov Ruslan Dropout: A Simple Way to Prevent Neural Networks from overfitting // Journal of Machine Learning Research 15. – 2014. – pp. 1929-1958.
5. 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.
6. Han J., Kamber M., Pei J. Data Mining Concepts and Techniques, 3rd Edition. – Elsevier Science, 2011. – 744 p.