

Поляков А.В., Попов А.В. Моделирование при помощи нейронных сетей для прогнозирования рисков, связанных с дифференциальными прихватами. // Проблемы информатики в образовании, управлении, экономике и технике: Сб. статей XVIII Междунар. научно-техн. конф. – Пенза: ПДЗ, 2018. – С. 67-71.

УДК 004.822

МОДЕЛИРОВАНИЕ ПРИ ПОМОЩИ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ РИСКОВ, СВЯЗАННЫХ С ДИФФЕРЕНЦИАЛЬНЫМИ ПРИХВАТАМИ

А.В. Поляков, А.В. Попов

SIMULATION USING NEURAL NETWORKS TO PREDICT THE RISKS ASSOCIATED WITH DIFFERENTIAL TACK

A.V. Polyakov, A.V. Popov

Аннотация. При конструировании нефтяных скважин можно столкнуться со множеством различных осложнений, но самые распространённые из них – дифференциальные прихваты. Они зависят от свойств бурового раствора и других параметров, связанных с характеристиками скальных образований. В настоящее время используется моделирование при помощи нейронных сетей для прогнозирования рисков, связанных с дифференциальными прихватами. В данной статье речь идёт об использовании метода нейронных сетей для решения проблемы, связанной с прихватами дифференциального давления.

Ключевые слова: искусственные нейронные сети, бурение скважин, прихват дифференциального давления.

Abstract. In the design of oil wells can face many different complications, but the most common of them – differential tack. They depend on the properties of drilling mud and other parameters related to the characteristics of rock formations. Currently, neural network modeling is used to predict the risks associated with differential tack. In this article we will focus on the use of neural network method to solve the problem associated with differential pressure seizures.

Keywords: artificial neural networks, well drilling, differential pressure capture.

Застраившая колонна – распространённая проблема, которая стоила промышленности сотни миллионов долларов по всему миру. Дифференциальные прихваты являются основной угрозой для инженеров-буровиков при бурении наклонных скважин с горизонтальными участками, особенно если речь идёт о морских операциях.

Впервые концепцию прихватов дифференциального давления разработали Хельмик и Лонгли, проведя соответствующие лабораторные тесты. Они считали, что дифференциальные прихваты получаются, когда под влиянием разности давлений в скважине и в проницаемом пласте неподвижная буровая колонна вдавливается в фильтрационную глинистую корку на открытой поверхности этого пласта.

Заклинивание на участках со сложной конфигурацией ствола получается там, где форма буровой колонны отличается от формы ствола и буровая колонна не может пройти по такому фрагменту. Если же буровую колонну продавливают в такой участок с использованием большой нагрузки, то вероятен прихват.

В прошлом для прогнозирования дифференциальных прихватов использовались методы многомерного статистического анализа и создавались симуляции с использованием различных растворов. На основе этого и собиралась статистика о том, какие факторы сильнее прочих влияют на возникновение дифференциальных при-

хватов. Исходя из этих данных можно сделать вывод о важности свойств антиприхваточного раствора (толщина, прочность на сдвиг и смазывающая способность). На эти свойства фильтрационной глинистой корки влияет комбинация таких факторов, как:

- перебалансировка раствора;
- содержание твердых веществ в растворе;
- тип бурового раствора (например, масляная, полимерная вода, гелевая вода и т.д.);
- конкретный состав раствора, включая наличие таких добавок, как смазочные материалы и мостовидные/точечно-формирующие частицы;
- потеря раствора.

В настоящее время для сбора статистики и прогнозирования возникновения дифференциальных прихватов стали применять методы с использованием искусственных нейронных сетей. Метод нейронных сетей обладает способностью представлять комплексные данные на основе множества переменных. Данная методология позволяет работникам буровой промышленности оценить риск заклинивания колонны не только при планировании скважин, но и при бурении. Правильное прогнозирование риска дифференциальных прихватов даст определение основным причинам возникновения проблем, а, следовательно, можно будет выбрать наилучшие методы для предотвращения прихвата колонны.

Прикладные нейронные сети

Искусственная нейронная сеть (ИНС) – математическая модель, а также её программное или аппаратное воплощение, построенная по принципу организации и функционирования биологических нейронных сетей – сетей нервных клеток живого организма. Ключевым элементом этой системы является новая структура системы обработки информации. Она состоит из большого количество сильно взаимосвязанных элементов обработки (нейронов), работающих в унисон для решения конкретных проблем ИНС. ИНС настроены для конкретного приложения, например, для распознавания образов или классификации данных, через процесс обучения.

Наиболее распространенные нейронные сети с прямой связью, используемые для предсказания: многослойный перцептрон Румельхарта (МПП) и радиально-базовая функция (РБФ). Многослойная нейронная сеть состоит из нескольких слоев (обычно 4). Входной слой является тем, который получает входящую информацию и обычно не выполняет никакой функции, кроме буферизации входного сигнала. Любой слой между входом и выходом называется скрытым, потому что находится внутри сети и не имеет прямого контакта с внешней средой. Нейроны в скрытом слое и выходной уровень выполняют функции активации.

Радиально-базовые функции (РБФ) – нейронные сети, которые содержат по крайней мере три слоя. Входной слой из входных узлов, скрытый слой с большим количеством узлов (нейронов) и выходной уровень, который содержит линейную комбинацию скрытых входных нейронов. Одной из самых популярных РБФ является функция Гаусса, которая может также аппроксимировать любую непрерывную нелинейную функцию.

Искусственные нейронные сети, такие как МПП и РБФ, проходят обучение, используя метод обратного распространения ошибки. Основная идея этого метода состоит в распространении сигналов ошибки от выходов сети к её входам, в направлении, обратном прямому распространению сигналов в обычном режиме работы.

Этапы работы

1. Сбор базы данных

Нейронные сети имеют возможность представлять различные вариации дифференциальных прихватов. Учитывая спецификации, приведенные в литературе, для прогнозирования по-разному застрявших колонн, нейронные сети анализируют девять различных параметров, связанных с характеристиками буровой скважины, раствора и окружающей среды.

Все эти параметры в основном независимы друг от друга. И именно их независимость и позволяет прогнозировать условия возникновения прихватов дифференциального давления.

2. Обучение

Данные в базе данных делятся на обучение, перекрестную проверку и подмножества тестирования.

Во время обучения входные и требуемые данные будут неоднократно отправляться в сеть. Со временем, обучаясь, сеть снизит количество ошибок до нуля. Отсутствие ошибок, однако, далеко не всегда значит, что сеть стала лучше. Существует вероятность того, что сеть «перетренируют» и она «запомнит» образцы, полученные при обучении и просто их обобщит. Обобщение относится к способности ИНС производить разумные результаты для входных данных, не встречающихся во время обучения.

Тут на помощь и приходит перекрёстная проверка. Когда число ошибок при перекрёстной проверке начнёт расти, то обучение следует прекратить, поскольку было достигнуто лучшее обобщение.

Лучшим испытанием для производительности сети является использование данных, которых она еще не видела. Если тренировка прошла успешно и топология сети верна, она будет применять свой прошлый опыт к новым данным и по-прежнему показывать хорошие результаты.

3. Критерии оценки и ограничения

Чтобы оценить производительность модели, сравниваются и анализируются два набора данных: минимальная ошибка обучения и ошибка обучения на последнем этапе.

4. Анализ чувствительности

После того как нейронная сеть была обучена, мы должны проверить, что каждый входной сигнал имеет выходной сигнал. Анализ чувствительности – метод изучения причинно-следственной связи между входными сигналами и выходными. Этот процесс тестирования обеспечивает относительное значение среди входов нейронной модели и иллюстрирует, как выход модели изменяется в зависимости от вариации ввода.

5. Оптимизация параметров

Анализ чувствительности данных для разных областей помогает узнать основные параметры, которые оказывают значительное влияние на увеличение риска возникновения дифференциального прихвата. Чтобы уменьшить эффект этих параметров, нужно высчитать их разумные и оптимальные значения, используя метод Монте-Карло и метод моделирования распределения параметров.

Выводы:

Нейронная сеть – мощный и эффективный инструмент, который эффективнее прочих методов позволяет спрогнозировать возникновение дифференциальных прихватов и подобрать грамотное решение для минимизации подобных рисков.

Успешность работы нейронной сети зависит от количества данных, которые будут занесены в её базу данных. При этом важно не «перетренировать» сеть, а также подобрать оптимальное количество слоёв для конкретной задачи.

Библиографический список

1. Тадеусевич Р., Боровик Б., Гончаж Т., Леппер Б. Элементарное введение в технологию нейронных сетей с примерами программ. М.: Горячая линия – Телеком, 2011. С. 277.
2. Тарик Рашид. Создаем нейронную сеть. М.: Вильям, 2018. С. 201.
3. Шаповалова А.В. Практическое применение искусственных нейронных сетей в обработке графической информации // Молодой ученый. 2017. № 10. С. 41-43.
4. Кулбараков М.А. К задаче прогнозирования энергопотребления с помощью нейронных сетей // Молодой ученый. 2014. № 11. С. 22-25.

Поляков Анатолий Владимирович

Тверской государственный
технический университет,
г. Тверь, Россия

Polyakov A.V.

Tver State Technical University,
Tver, Russia

Попов Александр Витальевич

Тверской государственный
технический университет,
г. Тверь, Россия
E-mail: popov_avit@mail.ru

Popov A.V.

Tver State Technical University,
Tver, Russia