

РАЗРАБОТКА ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ ПРИХВАТОВ КОЛОНН БУРИЛЬНЫХ ТРУБ

Ш.Ш. Кодиров, А.Л. Шестаков

Южно-Уральский государственный университет, г. Челябинск, Россия

Прихват колонны бурильных труб является одним из самых тяжелых видов аварий в бурении нефтяных и газовых скважин и оказывает существенное влияние на эффективность процесса бурения и стоимость скважины. Прогнозирование прихвата на стадии проектирования и в процессе бурения скважин позволяет минимизировать риск возникновения прихвата за счет выбора оптимального способа предупреждения для конкретных геолого-технических условий.

Статья посвящена разработке искусственной нейронной сети для прогнозирования прихвата колонны бурильных труб. Также приведен литературный обзор существующих методов прогнозирования прихватов. В качестве входных данных применяются важные и обобщающие факторы, влияющие на возникновение всех видов прихватов, что позволяет прогнозировать все виды прихватов колонн бурильных труб. С целью повышения восприимчивости входных данных к обучению нейронной сети производится преобразование элементов данных на субэлементы с последующей нормализацией. Экспериментальным методом выбирается тип и архитектура сети, а также ее гиперпараметры. Оценка качества работы сети производится методом кросс-валидации по k -блокам. Для нахождения оптимальной комбинации активационных функций с различными оптимизаторами проводятся экспериментальные исследования с дальнейшим анализом результатов.

Эксперименты реализованы на языке программирования Python с пакетами библиотек KERAS, TensorFlow и Matplotlib, а также в облачной платформе Colaboratory от компании Google.

Отличительной особенностью предлагаемого метода является то, что полученная модель прогнозирования легко может адаптироваться к новым данным, что часто происходит при бурении скважин на новых месторождениях.

Ключевые слова: прихват колонн бурильных труб, распознавание и прогнозирование, нейронные сети, многослойный перцептрон, нормализация данных, кросс-валидация по k -блокам.

Введение

Бурение скважин для разведки и разработки новых месторождений, а также добычи углеводородных ресурсов всегда было и остается чрезвычайно капиталоемким для нефтегазодобывающих организаций. Получение высоких технико-экономических показателей бурения во многом зависит от успешности преодоления осложнений и аварий. При этом риск возникновения аварий в современных условиях бурения нефтяных и газовых скважин (разнообразие геологического строения районов, глубина скважин, высокие давления, температура и солевая агрессия, наличие неустойчивых пород, сложность конструкций и конфигураций скважин) очень высок.

Наиболее распространенным и трудоемким видом аварий в процессе бурения скважин является прихват бурильной колонны, поэтому вопросам прогнозирования и идентификаций прихватов колонн бурильных труб отводится первостепенная роль.

Прихват – это непредвиденный процесс при сооружении скважин, характеризующийся потерей подвижности колонны труб или скважинных приборов при приложении к ним максимально допустимых нагрузок с учетом запаса прочности труб и применяемого оборудования [1]. Время простоя при ликвидации прихватов приводит к значительным финансовым убыткам. Следовательно, разработка методов прогнозирования и распознавания прихватов позволит получить значительную экономическую выгоду за счет сокращения времени на их ликвидацию [1–14].

В 70–80-е гг. XX в. коллективом ученых – А.К. Самогоем, А.Г. Аветисовым, Н.Н. Кошелевым, Н.Г. Аветисяном, М.М. Ахмадуллиным, С.Р. Хлебниковым – впервые была разработана процедура распознавания, прогнозирования и предупреждения прихватов колонн статистическими методами, а именно методом последовательной диагностической процедуры [1–6]. Данный метод авторы использовали для прогнозирования возникновения трех типов прихватов на основе промысловых данных. Авторы утверждают, что достоверность прогнозирования этого метода высокая (с вероятностью от 0,7 и более). Следует отметить, что такой подход требует значительного времени на проведение процедуры прогнозирования и получение больших статистических данных о прихватах. Следовательно, применение данного метода ограничено, особенно в геологически неразведанных районах.

Исследователем Ф.Н. Абу-Абед предложен метод обнаружения предаварийных ситуаций в процессе промышленного бурения нефтяных скважин [8–14]. В работах автора применяется кластеризация данных и последующее прогнозирование на основе нейронных сетей. В качестве входного набора данных автором использованы статистические данные об авариях, источник данных – библиотека программного обеспечения станции геолого-технологического исследования. В качестве выходного сигнала использованы два состояния текущей ситуации: «штатная ситуация» и «предаварийная ситуация». Работа автора охватывает все возможные виды аварий и некоторые осложнения в целом (газонефтеводопроявление и выбросы, поглощения бурового и тампонажного раствора, прихват бурового инструмента, обвал стенок скважины) без детализации причин их возникновения. Такой подход не позволяет оценить влияние конкретных факторов на развитие того или иного вида аварии, следовательно, устранение аварийных ситуаций на ранних стадиях становится невозможным.

Американскими учеными Хьюстонского университета и компании Халлибертон (A. Murillo, J. Neuman, R. Samuel) предлагается прогнозирование дифференциального и механического прихватов бурильных труб методами нечеткой логики и нейронной сети в сочетании с моделью дискриминантного анализа [15]. Исследование проведено на основе полевых производственных данных Халлибертон. В качестве входных данных были использованы параметры режимов бурения, глубина скважины, момент вращения, давление на стояке бурового насоса, диаметр долота, геометрия компоновки низа бурильной колонны и параметры бурового раствора, в том числе реологические. В результате полученная модель имеет достаточно высокую точность прогнозирования. Несмотря на то, что работа в большей степени посвящена дифференциальному прихвату труб, авторы не учитывали в своей модели типы горных пород. Однако именно данный фактор в большей степени влияет на природу возникновения дифференциального прихвата [1, 7].

Совместно с американскими и иранскими учеными (N.M. Elahi, P. Ezzatyar, J. Saeid) предлагается прогнозирование дифференциального прихвата бурильных труб методом нечеткой логики и активного обучения [16]. В качестве входных элементов данных применяются следующие факторы: глубина скважины, предел текучести бурового раствора (БР), тип БР, статическое напряжение сдвига при 1 и 10 мин покоя, тип смазочных добавок, содержание твердых частиц, водоотдача БР, толщина фильтрационной корки, пластическая вязкость, осевая нагрузка на долото и частота вращения инструмента. Авторы утверждают, что полученная ими модель по сравнению с существующими моделями [15] имеет высокую точность прогнозирования возникновения дифференциального прихвата. Несомненная важность этой работы состоит в том, что в ней применяется нормализация входных данных, за счет чего повышается точность модели. Однако в работе также не учитываются типы горных пород в качестве входных данных.

Таким образом, при наличии существенного задела по диагностике прихватов колонн бурильных труб многие свойства и механизмы возникновения прихватов недостаточно изучены. В данной работе представлен новый метод прогнозирования прихватов колонн бурильных труб на основе искусственной нейронной сети, при разработке которой были учтены наиболее важные факторы, влияющие на возникновение прихватов.

1. Подготовка данных

1.1. Выбор и преобразование набора входных данных

Успешное обнаружение и прогнозирование прихватов колонн бурильных труб возможно только при тщательном анализе комбинаций факторов, степень влияния которых разными исследователями определяется субъективно [1–7].

В качестве набора данных о прихватах в работе были использованы промышленные архивные данные ВНИИКРнефти по 92 прихватам скважин [1–6].

Рассматриваемые данные представляют собой следующие компоненты вектора состояния скважины ($X_1, X_2, X_3, X_4, X_5, X_6, X_7, X_8, X_9, X_{10}, X_{11}, X_{12}, X_{13}, X_{14}, X_{15}, X_{16}, X_{17}, X_{18}$), где

X_1 – глубина, на которой находится долото в момент прихвата, м;

X_2 – тип породы в зоне прихвата;

X_3 – пластовое давление в зоне прихвата, кгс/см²;

X_4 – разность между давлением столба промывочной жидкости и пластовым давлением, кгс/см²;

X_5 – плотность бурового раствора, г/см³;

X_6 – условная вязкость, с;

X_7 – СНС₁, мгс/см²;

X_8 – СНС₁₀, мгс/см²;

X_9 – водоотдача бурового раствора, см³/30 мин;

X_{10} – длина УБТ, м;

X_{11} – зазор между стенкой скважины и УБТ, мм;

X_{12} – угол искривления ствола скважины, градус;

X_{13} – температура на глубине прихвата, °С;

X_{14} – количество нефти в растворе, %;

X_{15} – понизители вязкости;

X_{16} – понизители водоотдачи;

X_{17} – ингибирующие добавки;

X_{18} – смазочные добавки.

Перечень компонентов вектора состояния скважины довольно представительен и при этом не противоречит набору априорных факторов, оказывающих первостепенное влияние на возникновение прихватов [2].

Для повышения информативности исходного вектора состояния ряд элементов вектора ($X_2, X_{15}, X_{16}, X_{17}, X_{18}$) был разделен на субэлементы. Каждому субэлементу данных было присвоено долевое значение в соответствии своего основного элемента данных (см. таблицу). Такое разделение позволило повысить репрезентативность выборки для нейронной сети (НС) и в дальнейшем улучшить качество ее работы.

Разделение элементов данных на субэлементы

X_2				X_{15}				X_{16}					X_{17}			X_{18}		
$X_{2.1}$	$X_{2.2}$	$X_{2.3}$	$X_{2.4}$	$X_{15.1}$	$X_{15.2}$	$X_{15.3}$	$X_{15.4}$	$X_{16.1}$	$X_{16.2}$	$X_{16.3}$	$X_{16.4}$	$X_{17.1}$	$X_{17.2}$	$X_{17.3}$	$X_{17.4}$	$X_{18.1}$	$X_{18.2}$	$X_{18.3}$
Тип породы в зоне прихвата. Глина, %	Тип породы в зоне прихвата. Аргиллит, %	Тип породы в зоне прихвата. Песчаник, %	Тип породы в зоне прихвата. Соль, %	Понизитель вязкости. ФХЛС, %	Понизитель вязкости. ТПФН, %	Понизитель вязкости. Окзил, %	Понизитель вязкости. УЦР, %	Понизитель водоотдачи. КССБ, %	Понизитель водоотдачи. Гипан, %	Понизитель водоотдачи. КМЦ, %	Понизитель водоотдачи. УЦР, %	Ингибирующие добавки. Мел, %	Ингибирующие добавки. Ж. стекло, %	Ингибирующие добавки. Соль, %	Ингибирующие добавки. Известь, %	Смазывающие добавки. Нефть, %	Смазывающие добавки. Графит, %	Смазывающие добавки. СМАД, %

Таким образом, имеются 32 компоненты вектора состояния, которые в наибольшей степени характеризуют состояние колонны бурильных труб, находящихся в стволе скважины. В качестве выходной информации о прихвате рассматривается 3 состояния: **I** – прихват под действием перепада давления; **II** – прихват (заклинивание) инструмента при его движении в скважине; **III** – прихват вследствие сужения сечения ствола скважины (в результате оседания шлама, утяжелителя, осыпей, обвалов, выпучивания пород, сальникообразования и т. п.).

1.2. Обучающие, проверочные и тестовые наборы данных

Оценка модели всегда сводится к делению доступных данных на три набора: *обучающий*, *проверочный* и *тестовый*. Модель будет обучаться на обучающих данных, а проверка качества обучения будет оцениваться на проверочных. После завершения обучения модель будет тестироваться с применением тестовых данных. Такой подход позволяет получить наиболее точную оценку обобщенности модели [17].

1.3. Нормализация данных

НС плохо работает со значениями элементов данных, имеющих самые разные диапазоны. Например, в нашем случае глубина нахождения долота – от 50 до 6000 м, плотность бурового раствора – от 0,890 до 1,80 г/см³ и т. д. Сеть сможет автоматически адаптироваться к таким разнородным данным, но это усложнит процесс обучения. На практике к таким данным принято применять нормализацию.

Нормализация – это ряд методов, стремящихся сделать сходство разных образцов более заметным для модели машинного обучения, что помогает модели выделять и обобщать новые данные. Для данной задачи подходит наиболее распространенная форма нормализации, которая предполагает нормальность закона распределения данных. Суть нормализации состоит в центрировании данных и приведении их к единичной дисперсии:

$$X_{\text{норм}i} = \frac{X_i - \bar{X}}{\sigma},$$

где \bar{X} – среднее значение по признаку X_i (элемента данных), σ – среднеквадратическое отклонение.

Важно отметить, что нормализации подвергаются обучающие и проверочные данные. Тестовые данные не должны подвергаться нормализации [17].

2. Подготовка НС

2.1. Тип и архитектура НС

Существуют различные типы и модели искусственных НС, которые различаются по принимаемым видам входной информации (графической, звуковой, текстовой, цифровой и т. д.), а также методам их обработки [19].

В математическом виде функционирование нейрона k можно описать следующей парой уравнений:

$$u_k = \sum_{m=1}^m w_{km} x_m, Y_k = \varphi(u_k + b_k),$$


где x_1, x_2, \dots, x_m – входные сигналы; $w_{k1}, w_{k2}, \dots, w_{km}$ – синаптические веса нейрона k ; u_k – линейная комбинация входных воздействий; b_k – порог; $\varphi(\cdot)$ – функция активации; Y_k – выходной сигнал нейрона.

Опираясь на существующие теории и результаты практического применения различных структур и моделей НС, для решения поставленной задачи была выбрана многослойная сеть с последовательными слоями (l_1, l_2, l_3) и полными связями между ними (модель *Sequential* или многослойный персептрон) [17–23].


Основным строительным блоком НС является *слой* (l_n). Существуют различные методики и рекомендации по расчету количества слоев, но на практике этот параметр обычно для каждой задачи выбирается индивидуально на основе численных экспериментов.

В качестве исходной архитектуры была выбрана следующая структура: сеть с входным слоем из 32 нейронов с функцией активации «ReLU» и с выходным слоем из 3 нейронов с функцией активации «SoftMax».

Далее был проведен ряд экспериментов, в которых оценивалось качество работы сети при изменении количества нейронов входного слоя. Результаты эксперимента (рис. 1а) показали, что увеличение количества нейронов входного слоя до 100 приводит к максимальной точности работы сети, а последующее увеличение приводит к нестабильному улучшению точности. С целью нахождения более точного количества нейронов в этом слое проведены повторные эксперименты в диапазоне от 92 до 108 нейронов с шагом один нейрон. Результаты эксперимента показали, что при количестве нейронов 97 точность работы сети достигает максимума (см. рис. 1а), следовательно, для выбранной сети оптимальное количество нейронов в первом слое составляет 97. Таким образом, эта процедура проведена для второго слоя (рис. 1б) и определено оптимальное количество нейронов 52. Дальнейшие увеличения количества слоев и нейронов в этих слоях не приводит к повышению точности работы сети.



а)



б)

Рис. 1. График точности работы сети в зависимости от количества нейронов в первом (а) и во втором (б) слое

Исходя из вышесказанного, обоснованно выбрана следующая архитектура сети: трехслойная сеть, где первый слой состоит из 97 нейронов, второй из 52 и последний третий (выходной) слой состоит из 3 нейронов. Во 2-м слое применяется активационная функция «Sigmoid», следовательно, на выходном слое применяется активационная функция мягкого максимума «SoftMax» (рис. 2).




Рис. 2. Архитектура НС. Многослойная сеть с последовательными связями

Функция активации ограничивает амплитуду выходного сигнала нейрона. Эта функция также называется функцией сжатия. Такая комбинация активационных функций выбрана исходя из результатов проведенных экспериментов, которые рассмотрены в разделе «оценка качества работы сети».

2.2. Алгоритм и метод обучения сети

Обучение НС – это процесс, в котором параметры НС настраиваются посредством моделирования среды, в которую эта сеть встроена. Существуют различные алгоритмы и методы обучения НС, в зависимости от архитектуры сети и постановки решаемой задачи. Так как модель рассматриваемой сети – это многослойный персептрон, то целесообразно применять алгоритм обучения сети с учителем и методом обратного распространения ошибки (со стохастическим градиентным спуском) [17–23].

Для подготовки сети к обучению прежде всего необходимо настроить три параметра для этапа компиляции:

1. *Функцию потерь* – величину, которую требуется свести к минимуму в ходе обучения, поэтому она должна представлять собой меру успеха для решаемой нами задачи. По своим назначениям существует множество видов функции потерь. В задачах мультиклассовой классификации (прогнозирования) целесообразно применять категориальную перекрестную энтропию (*Categorical cross-entropy*), которая описывается уравнением:

$$L_{ccek} = - \sum_{k=1}^n Y_k \log(\hat{Y}_k),$$

где \hat{Y}_k – предсказанное моделью значение целевой переменной; Y_k – желаемое значение целевой переменной.

2. *Оптимизатор* – механизм, с помощью которого сеть будет обновлять себя, опираясь на наблюдаемые данные и функцию потерь. Оптимизатор также определяет точный способ использования градиента потерь для изменения параметров (рис. 3). Применительно для нашей задачи наилучшие результаты были получены при выборе оптимизатора «Adam», реализующего градиентный спуск с импульсом.

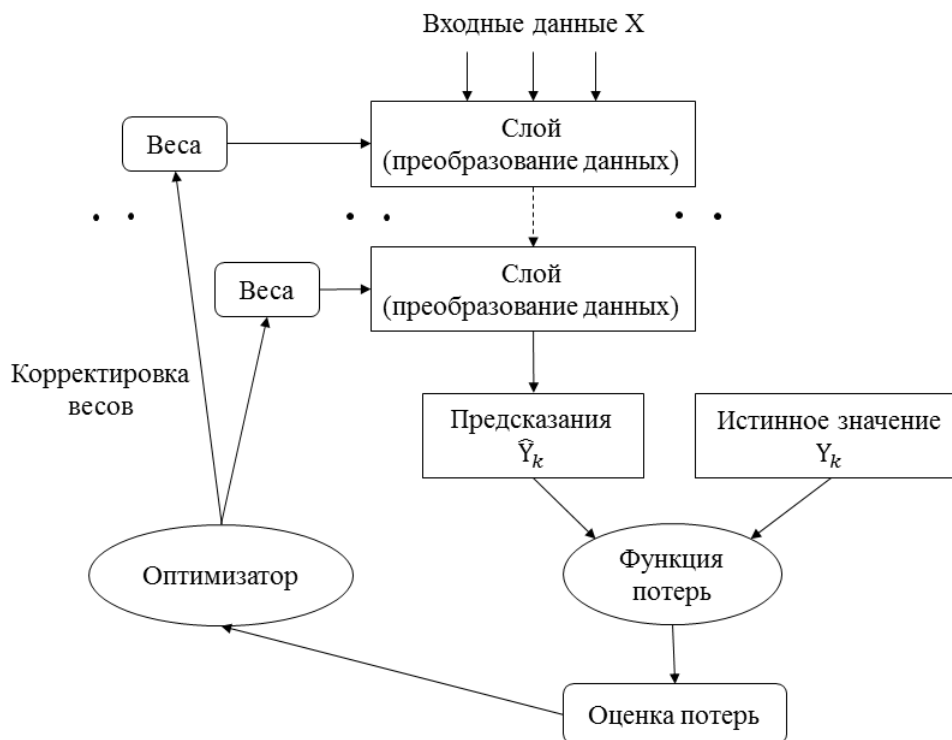


Рис. 3. Блок-схема процесса обучения сети [19]

3. Метрику для мониторинга на этапах обучения и тестирования мы выбрали «Accuracy» – это одна из удобных метрик качества моделей машинного обучения.

$$\text{Accuracy (точность)} = \frac{\text{Количество верных ответов}}{\text{Общее количество ответов}}$$

Она часто используется для классификации и показывает долю данных, для которых класс был определен правильно.

2.3. Настройка гиперпараметров сети

Интуитивно гиперпараметры можно представить как параметры, которые не были извлечены из данных и являются рычагами управления моделью, т. е. параметры, которые можно изменять с целью улучшения качества работы модели. Под гиперпараметрами следует понимать: размер мини-выборки, количество нейронов входного слоя, количество скрытых слоев НС и количество эпох обучения. Оптимальная настройка гиперпараметров может быть достигнута только в результате проведения серии экспериментов, в каждом из которых необходимо менять один из гиперпараметров и анализировать изменение качества работы сети. Первоначально эти параметры выбираются произвольно. Для используемой сети числом эпох обучения было выбрано 150. Но вскоре после проведения экспериментов и анализа результатов был отмечен следующий факт: по мере прохождения эпох обучения уменьшается доля ошибки на обучающей и проверочной выборке (рис. 4а). По мере увеличения эпох доля ошибки на проверочных данных в отличие от доли ошибок на обучающих данных достигает определенного уровня (минимума), после которого по мере увеличения эпохи начинает увеличиваться ошибка (происходит переобучение сети). В таком случае необходимо остановить процесс обучения на той эпохе, после которой замечено увеличение ошибок обучения сети. Судя по графику (см. рис. 4а) оптимальное число эпох для полного цикла обучения сети составляет 50, что подтверждается результатами повторного обучения (рис. 4б).

В результате проведенной серии экспериментов наилучшие результаты работы сети получены при следующих гиперпараметрах: размер мини-выборки 1; 97 нейронов входного слоя; 1 скрытый слой НС; 50 эпох обучения.

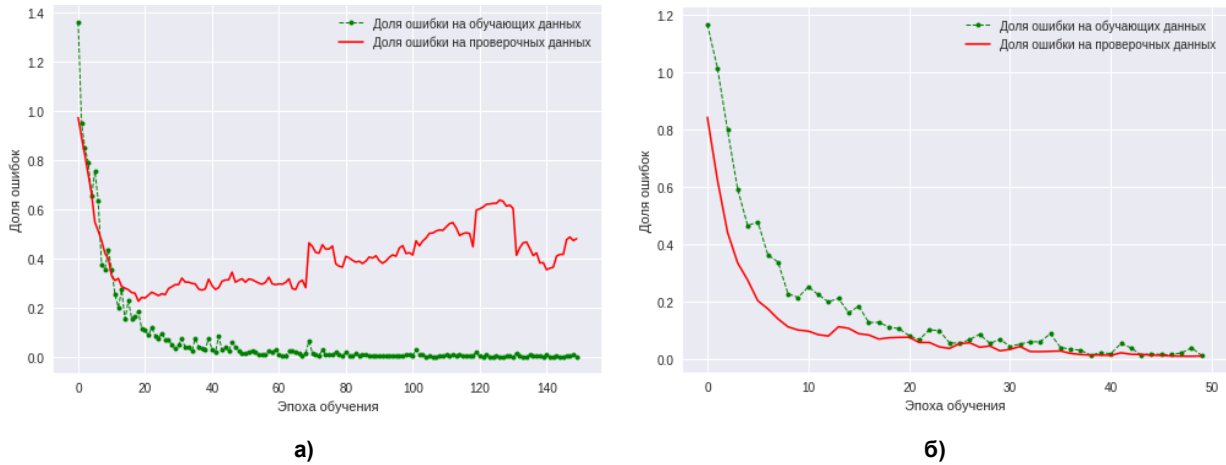


Рис. 4. График оценки ошибки сети на обучающих и проверочных данных по прохождению эпох обучения: а – при 150 эпохах; б – при 50 эпохах

3. Оценка качества работы сети

Оценка качества работы сети проводилась методом кросс-валидации по k -блокам. Имеющийся набор данных случайным образом подразделялся на 20-блоков мини-данных (рис. 5). В качестве обучающей выборки применялись 19 из них, а 1-блок мини-данных – в качестве проверочных. Данное разбиение блоков позволило проводить обучение сети и оценку ошибки сети на этих данных.

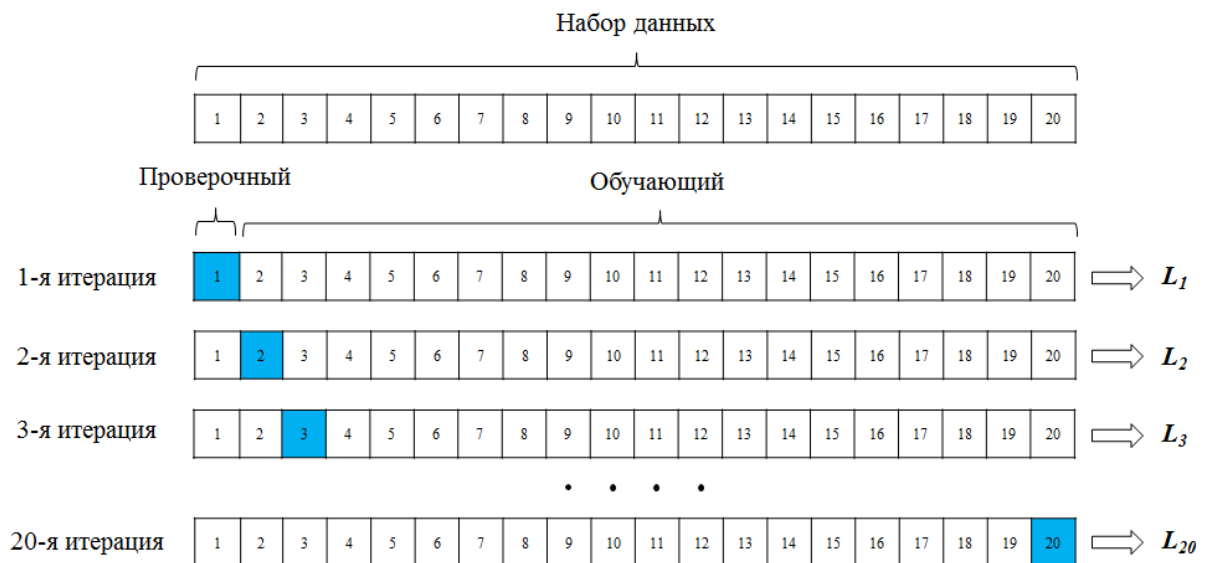


Рис. 5. Структурная схема кросс-валидации по k -блокам [20]

Процедура повторялась 20 раз, в результате чего, получено 20 моделей с их оценками качества работы сети ($L_1 \dots L_{20}$). Затем вычислялась средняя ошибка работы модели на основе разных независимых блоков:

$$L_{\text{mean}} = \frac{1}{20} \sum_{i=1}^{20} L_i .$$

Метод кросс-валидации по k -блокам позволил нам выполнить тонкие настройки модели, т. е. находить оптимальные значения гиперпараметров, которые дали удовлетворительную обобщающую способность. После того как определены удовлетворительные значения гиперпараметров, повторно произведен процесс обучения модели на полном обучающем наборе. В результате получена окончательная оценка качества модели на базе независимого тестового набора.

С учетом того, что k -блочная кросс-валидация – это метод генерирования повторных образцов без возврата (непересекающихся образцов), преимущество этого подхода заключается в том,

Информатика и вычислительная техника

что каждая точка образца является частью обучающего и проверочного наборов данных ровно один раз, что в итоге позволяет получить более низкодисперсную оценку качества модели [20].




Рис. 6. Точность работы сети при различных комбинациях активационных функций (скрытого и выходного слоя) с оптимизаторами: а – SGD; б – Adadelta; в – Adam

В результате проведения серии экспериментов с различными комбинациями активационных функций и оптимизаторами был получен ряд результатов (рис. 6), по которым можно сделать вывод о целесообразности применения комбинации активационных функций скрытого и выходного слоев «Sigmoid-SoftMax» с оптимизатором «Adam». При такой комбинации достигнута высокая точность работы сети (93,5 %) для обрабатываемых данных.

Заключение

Необходимо отметить, следующее:

- в разработке полученной модели прогнозирования применялись важные и обобщающие факторы, влияющие на возникновение всех видов прихватов, что позволяет прогнозировать все виды прихватов колонн бурильных труб;
- применяемый способ преобразования элементов входных данных позволяет адаптироваться полученной модели НС к новым выборкам, в том числе от скважин различных месторождений;
- экспериментальным способом обоснована архитектура сети и выявлены наилучшие гиперпараметры, а также комбинация активационных функций, которые позволили получить оптимальную модель для решения данной задачи;
- полученная модель может применяться в процессе проектирования и бурения скважины, что позволит минимизировать риски возникновения непредвиденных аварий (прихватов);
- разработанная модель позволяет прогнозировать возникновение и определять тип прихвата на экспериментальных данных с точностью прогнозирования 93 %.

Литература

1. Самотой, А.К. Предупреждение и ликвидация прихватов труб при бурении скважин: учеб. пособие / А.К. Самотой. – М.: Недра, 1979. – 182 с.
2. Самотой, А.К. Анализ априорных данных о факторах, действующих при прихвате колонны труб / А.К. Самотой, О.В. Воротнюк // Борьба с осложнениями при бурении скважин: тр. ВНИИБТ. – 1973. – Вып. 7. – С. 28–37.
3. Аветисов, А.Г. Прогнозирование, предупреждение и ликвидация прихватов с использованием статистических методов / А.Г. Аветисов, М.М. Ахмадуллин, А.К. Самотой // Тематический научно-технический обзор. – М.: ВНИИОЭНГ, 1977. – С. 75–86.
4. Аветисов, А.Г. Методическое руководство по распознаванию, прогнозированию и предупреждению прихватов колонн труб методом последовательной диагностической процедуры / А.Г. Аветисов, М.М. Ахмадуллин, Н.Н. Кошелев. – Краснодар: ВНИИКРнефть, 1977. – 38 с.
5. Мирзаджанзаде, А.Х. Методическое руководство по применению методов распознавания образов при промывке и креплении скважин / А.Х. Мирзаджанзаде, А.И. Булатов, А.Г. Аветисов. – Краснодар, 1974. – 42 с.
6. Мирзаджанзаде, А.Х. Методические указания по применению статистических методов в бурении нефтяных и газовых скважин / А.Х. Мирзаджанзаде, А.Г. Аветисов, А.И. Булатов. – Краснодар, 1983. – 62 с.
7. Липатов, Е.Ю. Исследование и разработка технологии и технических средств для предупреждения и ликвидации прихвата бурильной колонны (на примере месторождений Среднего Приобья): моногр. / Е.Ю. Липатов. – Тюмень: ТюмГНГУ, 2015. – 128 с.
8. Abu-Abed, F.N. Development of Tools for the Analysis of Pre-Emergency Situations on the Drilling Rig Based on Neural Network Technologies // IIIrd International Innovative Mining Symposium. Environment Saving Mining Technologies. – 2018. – 41, 01025. – 8 p. DOI: 10.1051/e3sconf/20184101025
9. Абу-Абед, Ф.Н. Надежность объектов нефтегазодобывающей промышленности / Ф.Н. Абу-Абед // Газовая промышленность. – 2015. – № S720 (720). – С. 107–111.
10. Абу-Абед, Ф.Н. Автоматизированная система обнаружения предаварийных ситуаций на объектах нефтегазодобывающей промышленности / Ф.Н. Абу-Абед // Каротажник. – 2015. – № 5 (251). – С. 48–61.
11. Абу-Абед, Ф.Н. Снижение риска при строительстве газовых скважин на базе нейросетевой модели / Ф.Н. Абу-Абед // Газовая промышленность. – 2014. – № S712 (712). – С. 100–102.
12. Абу-Абед, Ф.Н. Обнаружение предаварийных ситуаций в процессе промышленного бурения нефтяных скважин: дис. ... канд. техн. наук / Ф.Н. Абу-Абед. – Тверь, 2011. – 206 с.

13. Абу-Абед, Ф.Н. Применение средств моделирования нейросетей для анализа предаварийных ситуаций на буровых / Ф.Н. Абу-Абед, Р.В. Допира // Программные продукты и системы. – 2010. – № 3. – С. 136–139.
14. Абу-Абед, Ф.Н. Разработка средств моделирования нейросетей / Ф.Н. Абу-Абед // Вестник Тверского государственного технического университета. – 2005. – № 7. – С. 125–129.
15. Murillo, A. Pipe sticking prediction and avoidance using adaptive fuzzy logic and neural network modeling / A. Murillo, J. Neuman, R. Samuel // Paper presented at Production and Operations Symposium held in Oklahoma City. – Oklahoma, USA, 2009. – 15 p. SPE 120128. DOI: 10.2118/120128-MS
16. Morteza, E.N. Prediction of drilling pipe sticking by active learning method (ALM) / E.N. Morteza, E. Peyman, J. Saeid // Academic Journals. Journal of Petroleum and Gas Engineering. – 2013. – Vol. 4 (7). – P. 173–183. DOI: 10.5897/JPGE2013.0166
17. Шолле, Ф. Глубокое обучение на Python: справ. пособие / Ф. Шолле. – СПб.: Питер, 2018. – 400 с.
18. Gulli, A. Deep Learning with Keras: hand book / A. Gulli, S. Pal. – Birmingham – Mumbai: Packt, 2017. – 310 p.
19. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – М.: Издат. дом «Вильямс», 2006. – 1104 с.
20. Рашка, С. Python и машинное обучение: справ. пособие / С. Рашка. – М.: ДМК Пресс, 2017. – 418 с.
21. Грас, Дж. Наука о данных с нуля: учеб. пособие / Дж. Грас. – СПб.: БХВ-Петербург, 2017. – 336 с.
22. Jojo, M. Learn Keras for Deep Neural Networks: hand book / M. Jojo. – Canada: Apress, 2019. – 192 p.
23. Ketkar, N. Deep Learning with Python: A Hands-on Introduction / N. Ketkar. – India: Apress, 2017. – 162 p. DOI: 10.1007/978-1-4842-2766-4

Кодиров Шахбоз Шарифович, аспирант, младший научный сотрудник кафедры информационно-измерительной техники, Южно-Уральский государственный университет, г. Челябинск; asp18kss327@susu.ru.

Шестаков Александр Леонидович, д-р техн. наук, профессор, ректор, Южно-Уральский государственный университет, г. Челябинск; admin@susu.ac.ru.

Поступила в редакцию 5 мая 2019 г.

MSC 68T99, 86-08, (86A20)

DOI: 10.14529/ctcr190302

DEVELOPMENT OF ARTIFICIAL NEURAL NETWORK FOR PREDICTING DRILL PIPE STICKING

Sh.Sh. Qodirov, asp18kss327@susu.ru,

A.L. Shestakov, admin@susu.ac.ru

South Ural State University, Chelyabinsk, Russian Federation

Stuck piping is a common problem with tremendous impact on drilling efficiency and costs in oil industry. Prediction of stuck at the stage of designing and in the process of drilling wells, minimizes the risk of the occurrence of sticking, due to the choice of the optimal method of prevention for specific geological and technical conditions.

The article is devoted to the development of an artificial neural network for prediction of sticking of drill pipe columns. The paper provides a literature review of existing methods of prediction of

sticks. As input data elements are used important and generalizing factors influencing the emergence of all types of sticks, which allows predicting all types of sticks of drill pipe columns. In order to increase the susceptibility of the input data to the neural network, the data elements are transformed and normalized. The type and architecture of the network, as well as its hyperparameters, are chosen by the experimental method. Assessment of the quality of the network is made by the method of k -fold cross-validation. In order to find the optimal combination of activation function with various optimizers, experimental research is carried out with the analysis of their results.

The experiments were implemented in the Python programming language with KERAS, TensorFlow and Matplotlib library packages, as well as in the cloud platform Colaboratory from Google.

A distinctive feature of the proposed method is that the resulting forecasting model can be easily adapted to new data, which often occurs when drilling wells in new fields.

Keywords: drill string stuck, recognition and prediction, neural networks, multilayer perceptron, data normalization, k -fold cross-validation.

References

1. Samotoy A.K. *Preduprezhdenie i likvidatsiya prikhvatov trub pri burenii skvazhin: uchebnoe posobie* [Prevention and Elimination of Pipe Sticking in Well Drilling: Manual]. Moscow, Nedra Publ., 1979. 182 p.
2. Samotoy A.K., Vorotnyuk O.V. [Analysis of a Priori Data on the Factors Affecting the Sticking of the Pipe Column]. *Bor'ba s oslozheniyami pri burenii skvazhin: tr. VNIIBT* [Fight Against Complications at Well-Drilling], 1973, iss. 7, pp. 28–37. (in Russ.)
3. Avetisov A.G., Akhmadullin M.M., Samotoy A.K. [Prediction, Prevention and Liquidation of Sticking Pipe Using Statistical Methods]. *Tematicheskii nauchno-tehnicheskii obzor* [Thematic Scientific and Technical Review]. Moscow, VNIIOJeNG Publ., 1977, pp. 85–86. (in Russ.)
4. Avetisov A.G., Akhmadullin M.M., Koshelev N.N. *Metodicheskoe rukovodstvo po raspoznavaniyu, prognozirovaniyu i preduprezhdeniyu prikhvatov kolonn trub metodom posledovatel'noy diagnosticheskoy protsedury* [Methodological Guidance on the Recognition, Prognosis and Prevention of Drill String Sticks Using a Sequential Diagnostic Procedure]. Krasnodar, VNIKRneft' Publ., 1977. 38 p.
5. Mirzadzhanzade A.H., Bulatov A.I., Avetisov A.G. *Metodicheskoe rukovodstvo po primeneniyu metodov raspoznavaniya obrazov pri promyivke i kreplenii skvazhin* [Methodological Guidance on the Use of Pattern Recognition Techniques in Flushing and Fixing Wells]. Krasnodar, 1974. 42 p.
6. Mirzadzhanzade A.H., Avetisov A.G., Bulatov A.I. *Metodicheskie ukazaniya po primeneniyu statisticheskikh metodov v burenii neftyanykh i gazovykh skvazhin* [Methodological Guidelines on the Application of Statistical Methods in Oil and Gas Drilling]. Krasnodar, 1983. 62 p.
7. Lipatov E.Yu. *Issledovanie i razrabotka tekhnologii i tekhnicheskikh sredstv dlya preduprezhdeniya i likvidatsii prikhvata buril'noy kolonny (na primere mestorozhdeniy Srednego Priob'ya): monografiya* [Research and Development of Technology and Technical Means for Prevention and Liquidation of Drill String Sticking (on the Example of Middle Priobye Fields): Monograph]. Tyumen', TyumGNGU Publ., 2015. 128 p.
8. Abu-Abed F.N. Development of Tools for the Analysis of Pre-Emergency Situations on the Drilling Rig Based on Neural Network Technologies. *IIIrd International Innovative Mining Symposium. Environment Saving Mining Technologies*, 2018, 41, 01025. 8 p. DOI: 10.1051/e3sconf/20184101025
9. Abu-Abed F.N. [Reliability Objects of Oil and Gas Industry]. *Gas Industry*, 2015, no. S720 (720), pp. 107–111. (in Russ.)
10. Abu-Abed F.N. [Automated System for Detection of Pre-Emergency Situations at Oil and Gas Industry Facilities]. *Karotazhnik*, 2015, no. 5 (251), pp. 48–61. (in Russ.)
11. Abu-Abed F.N. [Risk Minimization during Construction of Gas Wells Based on the Neural Network Model]. *Gas Industry*, 2014, no. S712 (712), pp. 100–102. (in Russ.)
12. Abu-Abed F.N. *Obnaruzheniye predavariyinykh situatsiy v protsesse promyshlennogo bureniya neftyanykh skvazhin: dis. kand. tekhn. nauk* [Detection of Pre-Emergency Situations in the Process of Industrial Drilling of Oil Wells. Cand. Sci. Diss.]. Tver', 2011. 206 p.
13. Abu-Abed F.N. [Application of Neural Network Modeling Tools for Analysis of Pre-Emergency Situations on Drilling Sites]. *Software Products and Systems*, 2010, no. 3, pp. 136–139. (in Russ.)

14. Abu-Abed F.N. [Development of Neural Network Simulation Tools]. *Vestnik Tverskogo gosudarstvennogo tekhnicheskogo universiteta*, 2005, no. 7, pp. 125–129. (in Russ.)
15. Murillo A., Neuman J., Samuel R. Pipe Sticking Prediction and Avoidance Using Adaptive Fuzzy Logic and Neural Network Modeling. *Paper Presented at Production and Operations Symposium held in Oklahoma City*. Oklahoma, USA, 2009. 15 p. SPE 120128. DOI: 10.2118/120128-MS
16. Morteza E.N., Peyman E., Saeid J. Prediction of Drilling Pipe Sticking by Active Learning Method (ALM). *Academic Journals. Journal of Petroleum and Gas Engineering*, 2013, vol. 4 (7), pp. 173–183. DOI: 10.5897/JPGE2013.0166
17. François Chollet. *Deep Learning with Python: Manual*. Manning Publications, 2017. 386 p.
18. Gulli A., Pal S. *Deep Learning with Keras: Hand Book*. Birmingham – Mumbai: Packt, 2017. 310 p.
19. Haykin S. *Neyronnye seti: polnyy kurs* [Neural Networks: A Comprehensive Foundation]. Moscow, Williams Publ., 2006. 1104 p.
20. Raschka S. *Python Machine Learning*. Packt Publishing. Birmingham, 2015. 454 p.
21. Grus J. *Data Science from Scratch: First Principles with Python*. O'Reilly Media, 2015. 330 p.
22. Jojo M. *Learn Keras for Deep Neural Networks: Hand Book*. Canada: Apress, 2019. 192 p.
23. Ketkar N. *Deep Learning with Python: A Hands-on Introduction*. India: Apress, 2017. 162 p. DOI: 10.1007/978-1-4842-2766-4

Received 5 May 2019

ОБРАЗЕЦ ЦИТИРОВАНИЯ

Кодиров, Ш.Ш. Разработка искусственной нейронной сети для прогнозирования прихватов колонн бурильных труб / Ш.Ш. Кодиров, А.Л. Шестаков // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». – 2019. – Т. 19, № 3. – С. 20–32. DOI: 10.14529/ctcr190302

FOR CITATION

Qodirov Sh.Sh., Shestakov A.L. Development of Artificial Neural Network for Predicting Drill Pipe Sticking. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*, 2019, vol. 19, no. 3, pp. 20–32. (in Russ.) DOI: 10.14529/ctcr190302
