

Автоматизированные системы управления технологическими процессами Automated process control systems

Научная статья
УДК 004.032.26 + 622.248.54
doi: 10.14529/ctcr220111

МОДЕЛЬ И АЛГОРИТМ ПРОГНОЗИРОВАНИЯ ПРИХВАТА ТЕХНОЛОГИЧЕСКОГО ИНСТРУМЕНТА ПО ГЛУБИНЕ СТВОЛА СКВАЖИНЫ НА ОСНОВЕ ЧЕТЫРЕХМОДУЛЬНОЙ НЕЙРОННОЙ СЕТИ

Шахбоз Шарифович Кодиров¹, Александр Леонидович Шестаков²

^{1, 2} Южно-Уральский государственный университет, г. Челябинск, Россия

¹ shahboztjk@mail.ru

² admin@susu.ac.ru

Аннотация. Прихват технологического инструмента считается одним из самых капиталоемких видов аварий в бурении нефтяных и газовых скважин, которые оказывают существенное влияние на стоимость скважины. Прогнозирование прихвата технологического инструмента на стадии проектирования и в процессе бурения скважин позволяет минимизировать риски их возникновения, а также позволяет выбирать оптимальный способ предупреждения их возникновения для конкретных геолого-технических условий. Работа посвящена модели и алгоритму прогнозирования прихвата технологического инструмента по глубине ствола скважины на основе 4-модульной нейронной сети. В работе приведена классификация группы методов прогнозирования прихвата, а также критический обзор существующих методов. В работе приводится метод преобразования элементов входных данных на примере текстовых и категориальных типов данных. Благодаря этому в модели представляется возможность включения в перечень элементов входных данных ранее не воспринимаемые моделями такие геологические параметры, как типы горных пород, которые являются одним из важнейших факторов, влияющих на процесс возникновения прихвата. С целью формирования перечня значимых элементов входных данных представлен расчет коэффициентов корреляции между элементами входных данных и целевыми переменными. Экспериментальным методом выбирается тип и архитектура, а также гиперпараметры модульной нейронной сети. На основе обученной и проверенной 4-модульной модели прогнозирования предлагается алгоритм проведения процедуры прогнозирования прихвата на стадии проектирования и бурения скважины. Отличительной особенностью предлагаемого метода является то, что в модели прогнозирования в качестве элементов входных данных применяется широкий диапазон универсальных факторов, таких как геологические, технологические и реологические параметры бурового раствора, а также технико-технологические свойства и параметры бурения, влияющие на процесс возникновения всех типов прихвата. Предложенная модель в перспективе имеет возможность дообучаться и адаптироваться к новым данным, что часто происходит при бурении скважин на новых месторождениях.

Ключевые слова: классификация прихватов, методы распознавания и прогнозирования прихвата технологического инструмента, модульные нейронные сети, многослойный персептрон, структурная регуляризация dropout, алгоритм прогнозирования прихвата технологического инструмента, корреляционная матрица

Благодарности: Исследование выполнено при финансовой поддержке РФФИ и Челябинской области в рамках научного проекта № 20-48-740031.

Для цитирования: Кодиров Ш.Ш., Шестаков А.Л. Модель и алгоритм прогнозирования прихвата технологического инструмента по глубине ствола скважины на основе четырехмодульной нейронной сети // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2022. Т. 22, № 1. С. 125–138. doi: 10.14529/ctcr220111.

MODEL AND ALGORITHM FOR PREDICTING TECHNOLOGICAL TOOL STICKING BY WELLBORE DEPTH BASED ON THE FOUR-MODULE NEURAL NETWORK

Shahboz Sh. Qodirov¹, Aleksandr L. Shestakov²

^{1, 2} South Ural State University, Chelyabinsk, Russia

¹ shahboztjk@mail.ru

² admin@susu.ac.ru

Abstract. Sticking the technological tools is considered one of the most capital-intensive types of accidents in oil and gas well drilling, which have a significant impact on the cost of the well. The prediction of stuck tools at the design stage and in the process of drilling allows to minimize the risks of its occurrence, and also allows to choose the optimal method of prevention for specific geological and technical conditions. The work is devoted to the model and algorithm of predicting technological tool sticking by the wellbore depth based on a 4-module neural network. In the work presented classification of a group of methods for predicting sticking and the main disadvantages of existing methods. In the paper is presented the method of transformation the input data elements, on the example of textual and categorical data types. Due to this, it is possible to include into the list of input data elements such geological parameters as rock types, which are one of the most important factors influencing the process of sticking tools, and previously not perceived by models. In order to form a list of significant input data elements, the calculation of correlation coefficients between input data elements and target variables is presented. The type and architecture, as well as the hyperparameters of the modular neural network are chosen experimentally. Based on the trained and tested 4-module prediction model, we propose an algorithm for conducting a sticking tool prediction procedure at the design and drilling stage of the well. A specific feature of the proposed method is that the prediction model uses a wide diapason of universal factors as input data elements, such as geological, technological and rheological parameters of drilling mud as well as technical and technological parameters of drilling influencing the process of all types of stuck tools. Model in perspective has the ability to retrain and adapt to new data, which often happens when drilling wells in new fields.

Keywords: classification of stuck tools, methods of technological tool sticking recognition and prediction, modular neural networks, multilayer perceptron, dropout structural regularization, technological tool sticking prediction algorithm, correlation matrix

Acknowledgments: The research was funded by RFBR and Chelyabinsk Region, project number 20-48-740031.

For citation: Qodirov Sh.Sh., Shestakov A.L. Model and Algorithm for Predicting Technological Tool Sticking by Wellbore Depth Based on the Four-Module Neural Network. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*. 2022;22(1):125–138. (In Russ.) doi: 10.14529/ctcr220111.

Введение

В бурении нефтяных и газовых скважин одним из самых тяжелых видов аварий, является прихват технологического инструмента (ТИ). Прихват ТИ – это сложный и быстропротекающий процесс, возникающий при нарушении условий устойчивости (стабильности) ствола скважины и подвижности колонны буровых труб в стволе скважины, который приводит к потере подвижности технологического инструмента и невозможности дальнейшего углубления забоя скважины [1–3]. Несмотря на применение современных средств, технологий и оборудования для сооружения скважин при ведении буровых работ, прихваты все еще составляют весьма высокую долю (от 26 до 60 %) от общего числа встречающихся аварий [1–12]. В скважинах, в которых происходили прихваты, до 40 % из них перебуривались или ликвидировались, до 10 % прихваты в этих скважинах были ликвидированы более чем за 4 часа, и до 50 % среди них были ликвидированы менее чем за 4 часа, что приводило к большим убыткам за счет потери инструмента, потери пробуренной части ствола скважины, потери временных и материальных ресурсов, затраченных на перебуривание нового ствола [1–3]. Эти убытки становятся еще более серьезными, если в состав компоновки прихваченной части технологического инструмента входит забойная телеметрическая система.

Как было отмечено в работах [13, 14], по механизмам и причинам возникновения различают три типа прихвата: а) *дифференциальный прихват*; б) *прихват вследствие геометрических изменений ствола скважины*; в) *прихват вследствие зашламования или закупоривания кольцевого пространства твердыми частицами* [1–14]. Последние два типа (б и в) в зарубежной литературе именуются как механический прихват [1–9].

Прихват можно предотвратить, если по ранним, а также известным признакам правильно идентифицировать начальные условия возникновения того или иного вида прихватов и предпринимать своевременные меры, которые в нефтегазовом деле принято называть «предупреждением прихватов». Существует набор методов по предупреждению прихватов, которые обеспечивают безопасность и не требуют больших трудовых или материальных затрат. Однако своевременное распознавание и прогнозирование прихватов является сложной задачей, поскольку одни и те же наблюдаемые свойства, параметры и режимы бурения в разных ситуациях, условиях и операциях могут интерпретироваться по-разному. Достоверно распознавать и прогнозировать прихваты можно только, если учитывать большой набор влияющих факторов, что в полевых условиях в настоящее время не всегда возможно. Соответственно, разработка методов распознавания и прогнозирования прихватов, учитывающих множество важных факторов, позволит минимизировать риски возникновения непредвиденных прихватов. Следовательно, это позволит сократить финансовые, материальные и трудовые затраты во время буровых работ за счет сокращения времени на ликвидацию прихватов [1–3, 13].

По результатам глубокого анализа существующих методов и способов распознавания и прогнозирования прихватов было установлено, что все методы по физическому смыслу условно разделяются на две группы: *I – группа методов распознавания и прогнозирования прихватов по глубине ствола скважины*, заключающихся в том, что методами учитываются свойства и параметры по интервалам бурения скважины и выдаются прогнозы в виде вероятности возникновения прихватов, соответственно также по интервалам бурения; *II – группа методов распознавания и прогнозирования прихватов по времени бурения скважины*, заключающихся в том, что методами учитываются изменения значений множества параметров и режимов бурения по времени нахождения технологического инструмента в стволе скважины и выдаются прогнозы тоже по времени в виде вероятности возникновения прихвата по истечении определенного интервала времени [15].

В данной работе рассматриваются методы распознавания и прогнозирования прихватов по глубине бурения скважины.

Исследования в области развития и разработки методов распознавания и прогнозирования прихватов рассматривались в трудах отечественных и зарубежных учёных. Анализ наиболее значимых разработок зарубежных и отечественных авторов подробно рассмотрен в работах [13, 14]. Но следует отметить, что мнения отечественных и зарубежных ученых имеют расхождение в вопросе формулирования перечня входных данных (факторов, влияющих на процесс возникновения прихватов). Например, в работах авторов [2, 4–9] в качестве элементов входных данных применяются механические и динамические параметры и режимы бурения, такие как: осевая нагрузка на долото, частота вращения долота, крутящий момент, давление на стояке бурового насоса, расход бурового раствора, механическая скорость бурения. На практике бурения по этим показателям можно судить о начале возникновения прихватов, только если анализировать динамику изменения этих показателей за определенный промежуток временной последовательности. Но авторы используют мгновенные показатели и не учитывают динамику изменений этих параметров. Например, по показаниям крутящего момента практически невозможно распознавать прихват вследствие желобообразования, и это возможно только при анализе динамики изменения ряда параметров и режимов. По мгновенным показаниям механических и динамических параметров и режимов бурения распознавать или прогнозировать прихват не эффективно, так как они не описывают полноту процессов возникновения прихвата и сами зависят от множества других параметров. Следовательно, перечень упомянутых элементов входных данных не только не информативен, порой в некоторых случаях даже противоречив (см. [9], табл. 6–9 в работе).

Необходимо также отметить, что в своих моделях авторы не учитывали геологические параметры, такие как тип горной породы в зоне прихвата в качестве элемента входных данных. Одна-

ко для распознавания и прогнозирования прихватов по глубине ствола скважины данный фактор очень важен, так как в большей степени влияет на процесс возникновения прихватов, особенно дифференциального типа [1, 3].

В свою очередь, отечественными исследователями был проведен опрос специалистов, занимавшихся данной проблемой, о степени влияния различных факторов на возникновение прихватов. По результатам анализа существующих точек зрения с последующей статистической обработкой результатов ими был сформулирован перечень 18 факторов [10–12]. Перечень этих факторов подробно будут рассмотрены далее. Соответственно, нами тоже был осуществлен сбор данных о прихватах по этим 18 факторам.

Несмотря на огромный вклад указанных выше и других авторов, вопрос распознавания и прогнозирования прихвата ТИ все еще остается недостаточно изученной задачей. И в предложенных методах есть определенные недостатки, которые выше были подчеркнуты. Помимо этого, следует также отметить, что авторами не рассматривались применения модульных нейронных сетей, которые имеют высокую производительность в решении задачи мульти-классовой классификации и прогнозирования [16, 17].

На основе вышесказанного важной задачей является разработка модели прогнозирования прихвата с применением модульной нейронной сети, учитывающей важные и обобщающие факторы, влияющие на процесс возникновения прихвата. Данная статья посвящена разработке модели прогнозирования прихвата технологического инструмента по глубине ствола скважины на основе 4-модульной нейронной сети.

1. Подготовка набора данных о прихватах по глубине ствола скважины

В рассматриваемой работе в качестве набора данных о прихватах были использованы промысловые данные о прихватах ООО «НК ПАРИТЕТ», ООО «РУСГЕОСЕРВИС», а также архивные данные ВНИИКРнефти и ГУП «Таджикнефть» по 146 прихватам скважин, в том числе 38 из них – дифференциальный прихват, 49 – прихват вследствие геометрических изменений ствола скважины и 59 – прихват вследствие зашламования или закупоривания кольцевого пространства твердыми частицами.

1.1. Перечень элементов входных данных

В модели в качестве элементов входных данных применяются косвенно-диагностические параметры (КДП), такие как: $X_{1.1}$ – глубина, на которой находится долото в момент прихвата, м; $X_{1.2}$ – наружный диаметр долота, мм; X_2 – тип горных пород в предполагаемой зоне прихвата; X_3 – пластовое давление в предполагаемой зоне прихвата, кгс/см²; X_4 – разность между давлением столба промывочной жидкости и пластовым давлением, в предполагаемой зоне прихвата, кгс/см²; X_5 – плотность бурового раствора, г/см³; X_6 – условная вязкость, с; X_7 – статическое напряжение сдвига при одной минуте в покое (СНС₁), мгс/см²; X_8 – статическое напряжение сдвига при 10 минутах в покое (СНС₁₀), мгс/см²; X_9 – водоотдача бурового раствора, см³/30 мин; X_{10} – длина компоновки низа бурильной колонны (КНБК), м; X_{11} – зазор между стенкой скважины и наружным диаметром максимально длинной части КНБК, мм; X_{12} – зенитный угол участка ствола скважины, градус; X_{13} – температура на глубине прихвата, °С; X_{14} – количество нефти в растворе, %; X_{15} – компоненты понизителя вязкости; X_{16} – компоненты понизителя водоотдачи; X_{17} – компоненты ингибирующей добавки; X_{18} – компоненты смазывающей добавки.

1.2. Преобразование некоторых элементов входных данных

Эти диагностические параметры по характеру описаний условно разделяются на *геологические* (X_2, X_3, X_{13}), *технологические и реологические параметры бурового раствора* ($X_4, X_5, X_6, X_7, X_8, X_9, X_{14}, X_{15}, X_{16}, X_{17}, X_{18}$), *технично-технологические параметры бурения* ($X_{1.1}, X_{1.2}, X_{10}, X_{11}, X_{12}$), а также по степени управляемости условно разделяются на *управляемые* ($X_6, X_7, X_8, X_9, X_{10}, X_{11}, X_{14}, X_{15}, X_{16}, X_{17}, X_{18}$) и *неуправляемые* ($X_{1.1}, X_{1.2}, X_2, X_3, X_4, X_5, X_{12}, X_{13}$) параметры. По степени изменчивости по времени они условно считаются статическими [10–12].

Как видно из описаний, некоторые косвенно-диагностические параметры, такие как X_2 , X_{15} , X_{16} , X_{17} и X_{18} , не числовые, а категориальные. Следовательно, разработка моделей на таких типах данных без дополнительного преобразования невозможна. Один из методов преобразования таких типов данных – это разделение элемента данных на субэлементы. Соответственно, данный метод был применен к нашим данным. Суть этого метода заключается в следующем: каждый элемент данных разделяется на субэлементы и каждому субэлементу данных присваиваются долевое значение в соответствии со своим основным элементом данных (табл. 1) [13, 14]. Такое разделение или своего рода кодирование позволяет повысить информативность выборки для нейронной сети и в дальнейшем улучшить качество ее работы [13].

Разделение элементов данных на субэлементы [13, 14]

Таблица 1

Table 1

Dividing data elements into sub-elements [13, 14]

X_2 – тип горных пород в зоне прихвата				X_{15} – понизители вязкости				X_{16} – понизители водоотдачи				X_{17} – ингибирующие добавки				X_{18} – смазывающие добавки		
$X_{2.1}$	$X_{2.2}$	$X_{2.3}$	$X_{2.4}$	$X_{15.1}$	$X_{15.2}$	$X_{15.3}$	$X_{15.4}$	$X_{16.1}$	$X_{16.2}$	$X_{16.3}$	$X_{16.4}$	$X_{17.1}$	$X_{17.2}$	$X_{17.3}$	$X_{17.4}$	$X_{18.1}$	$X_{18.2}$	$X_{18.3}$
Тип 1, %	Тип 2, %	Тип 3, %	Тип 4, %	Компонент 1, %	Компонент 2, %	Компонент 3, %	Компонент 4, %	Компонент 1, %	Компонент 2, %	Компонент 3, %	Компонент 4, %	Компонент 1, %	Компонент 2, %	Компонент 3, %	Компонент 4, %	Компонент 1, %	Компонент 2, %	Компонент 3, %

После того как некоторые элементы выборки были преобразованы, в результате были получены 35 компонентов КДП, которые косвенно характеризуют состояние технологического инструмента, находящегося в стволе скважины, на предмет возможного риска возникновения прихвата. Так как набор имеющихся данных состоит из трех групп прихватов, в качестве выходной информации о прихвате рассматривается 4 возможных состояния: Y_1 – дифференциальный прихват (под действием перепада давления); Y_2 – прихват вследствие геометрических изменений ствола скважины; Y_3 – прихват вследствие зашламования или закупоривания кольцевого пространства твердыми частицами; Y_4 – отсутствие прихвата.

1.3. Корреляционная матрица

Корреляционный анализ, как правило, используется как вспомогательный инструмент для понимания качества данных. Одним из важных показателей корреляционного анализа является коэффициент корреляции. Этот коэффициент в большинстве случаев рассчитывается для пары переменных, то есть между элементом набора данных – X_g и целевой переменной – Y_q .

Существует множество методов расчета коэффициента корреляции, среди которых часто применяемыми являются методы Пирсона, Спирмена и Кендалла. В решаемой задаче воспользуемся методом Спирмена, так как этот метод не требует строгих соблюдения нормального закона распределения для элементов данных в выборке и линейной зависимости между парами переменных [18]. Следовательно, для оценки статистической взаимосвязи между парами переменных из числа элементов входных данных и целевой переменной, на имеющихся исходных данных о прихватах по глубине ствола скважины произведен расчет коэффициентов корреляции. Результаты расчетов представлены на рис. 1а, 1б и 1с в виде корреляционной матрицы.




Рис. 1а. Корреляционная матрица, часть 1
Fig. 1a. Correlation matrix, part 1




Рис. 1б. Корреляционная матрица, часть 2
Fig. 1b. Correlation matrix, part 2




Рис. 1с. Корреляционная матрица, часть 3
Fig. 1c. Correlation matrix, part 3

По значениям коэффициентов корреляции все элементы входных данных были разделены на два списка: коррелирующие и слабокоррелирующие элементы. Далее для оценки значимости слабокоррелирующих элементов входных данных проводились экспериментальные исследования: обучалась и оценивалась сеть с участием всех элементов данных. А также обучалась и оценивалась сеть с последовательным исключением слабокоррелирующих элементов данных. Анализ результатов со сравнением мер ошибок работы сети показал, что все элементы входных данных имеют весомое влияние на качество работы сети и их исключать из набора данных нецелесообразно.

1.4. Разделение набора данных с последующей нормализацией значений их элементов

Для получения более точной и обобщенной оценки работоспособности модели [19–21] имеющийся набор данных был разделен на три непересекающиеся подвыборки: тренировочную, проверочную и тестовую, с последующей нормализацией значений элементов подвыборок. Это делалось для того, чтобы разрабатываемую модель обучить на тренировочной подвыборке, а процесс обучения модели оценивать на проверочной подвыборке. Соответственно, по завершении процесса обучения и проверки модели тестировать обученную модель с применением тестовой подвыборки.

Что касается нормализации, то это делалось с целью центрирования данных и приведения их к единичной дисперсии [13, 19–21]:

$$X_{\text{норм}_g} = \frac{x_g - \bar{X}}{\sigma}, \quad (1)$$

где \bar{X} – среднее значение по X_g -му элементу данных; σ – среднеквадратическое отклонение.

2. Модульные нейронные сети

Модульные нейронные сети применяются при решении многих инженерных задач, особенно в задачах классификаций, в большинстве случаев превосходят результаты решения, полученные полносвязанными сетями [16, 17, 19]. Это связано с тем, что каждый отдельный модуль извлекает свои независимые признаки одного класса из нескольких классов. Таким образом, каждый модуль воспроизводит неповторимый другими модулями результат, следовательно, объединение выходных сигналов всех модулей в единую сеть позволяет повысить точность работы сети [16, 17, 19].

Основной проблемой проектирования модульных нейронных сетей является задача оптимального выбора структуры и топологии нейронной сети, а также правильная организация количества модулей [19]. В данной части работы в качестве модуля будет использована трехслойная полносвязанная нейронная сеть с оптимальными параметрами из работы [13].

Что касается организации количества модулей, то из условия оптимальности организации модульной нейронной сети [16, 17, 19] известно, что если на входы каждого модуля подавать одинаковые элементы набора данных и при этом конфигурации модулей идентичны между собой, тогда в процессе обучения сети каждый модуль будет извлекать одинаковые признаки (паттерны). То есть модули будут копировать друг друга, следовательно, смысл модульности сети пропадает, так как результаты работы такой сети ни чем не лучше полносвязанной сети с такими же конфигурациями. Для успешной разработки модульной сети необходимо, чтобы на входы каждого модуля поступали различные части элементов набора входных данных (не знакомые другим модулям части элементов данных) или их сочетание. В таком случае результаты работы полученной модульной сети будут значительно отличаться от результатов работы полносвязанной сети [16, 17, 19].

Как было отмечено выше, элементы набора данных о прихватах по глубине ствола скважины, состоящие из диагностических параметров, по характеру описаний условно разделяются на геологические, технологические и реологические параметры бурового раствора и технико-технологические параметры бурения. Исходя из этого, предлагается модульная сеть, состоящая из четырех модулей, каждый из которых представляет собой трехслойную ПНС из работы [13]. Соответственно, модули между собой имеют идентичные структуры за исключением входов, которые отличаются по качеству и количеству. Например, на входы: первого модуля поступают элементы данных, описывающие геологические параметры; второго модуля – элементы данных,

описывающие технологические и реологические параметры бурового раствора; третьего модуля – элементы данных, описывающие технико-технологические параметры бурения; четвертого модуля – все элементы данных, в том числе геологические параметры, технологические и реологические параметры бурового раствора, а также технико-технологические параметры бурения. Модули между собой построены параллельно, но выходы у них объединены полносвязанными слоями интегратора, который в свою очередь имеет 12 нейронов во входном слое, 128 нейронов в скрытом и, соответственно, 4 в выходном слое, так как имеем 4 группы образцов данных (рис. 2) [16, 17, 19]. Предложенная четырехмодульная нейронная сеть построена по стратегии стек-ансамблирования (stacking ensemble strategies) [16, 17, 19–21].

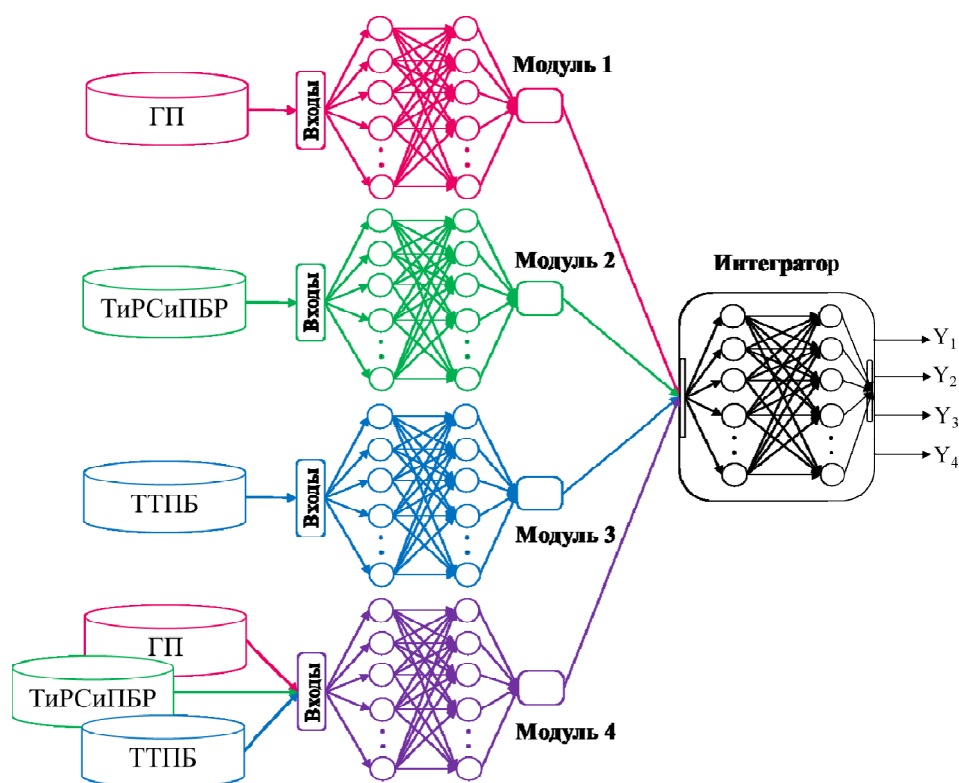


Рис. 2. Архитектура четырехмодульной нейронной сети: ГП – геологические параметры; ТиРСиПБР – технологические и реологические свойства и параметры бурового раствора; ТТПБ – технико-технологические параметры бурения

Fig. 2. The architecture of the four-module neural network: ГП – geological parameters; ТиРСиПБР – technological and rheological properties and parameters of the drilling fluid; ТТПБ – technical-technological parameters of drilling

Так как модульные сети относятся к многослойным персептронам, то, соответственно, для данной сети применяется алгоритм обучения сети с учителем и метод обратного распространения ошибки [19–21].

2.1. Функция ошибки работы сети

Для успешной реализации процесса обучения нейронной сети необходимо правильно определить функцию ошибки с учетом условия решаемой задачи и желаемого результата. *Функция ошибки* – это целевая функция, величину которой необходимо минимизировать в ходе обучения сети, следовательно, для решаемой нами задачи она будет представлять собой критерий успеха. Поскольку выходная информация рассматриваемой задачи имеет вероятностное распределение, в качестве *функции ошибки* применяем категориальную перекрестную энтропию (*Categorical cross-entropy*), которая задаётся выражением [13, 14, 19–21]:

$$L_{loss_q} = - \sum_{q=1}^4 Y_q \log(\hat{Y}_q), \quad (2)$$

где \hat{Y}_q – предсказанное моделью значение целевой переменной; Y_q – желаемое значение целевой

переменной [19]. Целевая переменная \hat{Y}_q представляет собой вектор из q элементов, соответствующий истинному полиномиальному распределению вероятности по всем классам. Если правильно определен только один класс, то вектор будет унитарным. Выходные данные сети (Y_q) также представляют собой вектор из q элементов, но соответствующий уже предсказанному сетью полиномиальному распределению вероятности. Категориальная перекрестная энтропия оценивает потери путем сравнения этих двух векторов (Y_q, \hat{Y}_q).

2.2. Мера оценки качества работы сети

В качестве меры оценки качества работы сети для мониторинга на этапах обучения, проверки и тестирования сети выберем меру *Accuracy* (*ACC*), так как имеющиеся исходные данные о прихватах по глубине ствола скважины имеют относительно симметричную пропорцию групп образцов данных. Мера *ACC* описывается следующим выражением [19–21]:

$$ACC = \frac{TP+TN}{TP+TN+FP+FN}, \quad (3)$$

где TP – (true positive) количество верно предсказанных сетью прихватов; TN – (true negative) количество верно предсказанных сетью отсутствующих прихватов; FP – (false positive) количество неверно предсказанных сетью прихватов; FN – (false negative) количество неверно предсказанных сетью отсутствующих прихватов.

Данная мера в основном используется в задачах классификации и отображает долю точности работы сети. Под долей точности в рассматриваемой работе подразумевается вероятность правильного прогнозирования с распознаванием видов прихвата.

2.3. Оптимизатор процесса обучения сети

Оптимизатор – это алгоритм, с помощью которого сеть будет обновлять веса синаптических связей, опираясь на наблюдаемые данные и величины функции ошибки. Существует множество типов оптимизаторов, но ни один из них не может быть универсальным или лучшим для всех типов задач. Каждая задача имеет свою архитектуру сети, следовательно, оптимизатор для такой сети тоже будет специфическим. На практике оптимизатор выбирается только по результатам серии экспериментальных вычислений с сопоставлением результатов качества работы сети по каждому оптимизатору. По результатам экспериментальных вычислений для решаемой задачи среди множества типов оптимизаторов, в том числе SGD, Adadelta, Adagrad, Adam, Adamax, Adaline, Nadam и RMSprop, был определен наилучший оптимизатор – Adam (Adaptive Moment Estimation), работающий по стратегии градиентного спуска, но только с импульсом [19–21].

2.4. Структурная регуляризация dropout

Глубокие нейронные сети с большим количеством слоев способны создавать коадаптации элементов. «Коадаптация» – термин из нейронауки, означающий ситуацию, при которой связь между двумя элементами становится чрезвычайно сильной за счет ослабления связей между другими элементами. Обычно это приводит к переобучению модели на текущих данных. Один из вариантов борьбы с переобучением сети – это структурная регуляризация под названием «вероятностное прореживание» (на английском dropout). Во время обучения прореживание на вероятностной основе отбрасывает некоторые межнейронные связи в слоях [19–21].

Вероятностное прореживание межнейронных связей позволяет гарантировать, что никакой конкретный нейрон не окажется в постоянной зависимости от другого конкретного нейрона, благодаря чему модели становятся ошибкоустойчивыми. Прореживание не требует добавления в модель дополнительных параметров, а лишь одного гиперпараметра – «коэффициента прореживания».

В нашем случае экспериментальным способом выбраны коэффициенты прореживания 0,3 для второго и третьего слоев каждого модуля, а также для второго слоя интегратора.

Важно отметить, что прореживание применяется только во время обучения, следовательно, на этапе тестирования прореживание не производится [19].

В результате имеем четырехмодульную нейронную сеть с наилучшими гиперпараметрами, которые представлены в табл. 2.

Основные параметры четырехмодульной нейронной сети

Таблица 2

Table 2

The main parameters of the four-module neural network

Параметры сети	Модуль 1	Модуль 2	Модуль 3	Модуль 4	Интегратор
Количество входов	8	22	5	35	16
Количество входов сети из числа элементов входных данных или выходов модулей и моделей	97	97	97	97	128
Функция активации первого слоя	–	–	–	–	ReLU
Коэффициент прореживания (dropout)	0,3	0,3	0,3	0,3	0,3
Количество нейронов во втором слое	52	52	52	52	52
Функция активации второго слоя	ReLU	ReLU	ReLU	ReLU	Sigmoid
Коэффициент прореживания (dropout)	0,3	0,3	0,3	0,3	–
Количество нейронов в выходном слое	4	4	4	4	4
Функция активации выходного слоя	ReLU	ReLU	ReLU	ReLU	Softmax
Тип функции ошибки сети	Категориальная перекрестная энтропия (Categorical cross-entropy)				
Тип оптимизатора сети	Adam				
Мера оценки качества работы сети	Accuracy (ACC)				
Количество эпох обучения сети	40–80				

Результаты вычислительных экспериментов на тестовой подвыборке показали, что точность работы четырехмодульной нейронной сети, которая имеет вероятность правильного прогнозирования с распознаванием видов прихвата 0,96, превосходит точность работы полносвязанной сети из работы [13], имеющей вероятность правильного прогнозирования с распознаванием видов прихвата 0,935.

2.5. Результаты вычислительных экспериментов

После того как модель прогнозирования была обучена и протестирована, приступают к процедуре экспериментальной оценки работоспособности модели, которая выполняется по следующему алгоритму (рис. 3) [14]: измеряют, определяют или рассчитывают косвенно-диагностические параметры бурения скважины (КДП) (рис. 3, позиция 1) для прогнозируемого интервала бурения бурящейся (или проекта) скважины. Производят нормализацию значений КДП (рис. 3, позиция 2) и передают в модель прогнозирования (рис. 3, позиция 3), которая, в свою очередь, выдает прогноз на прихват (рис. 3, позиция 4). Если модель прогнозирует (рис. 3, позиция 4) отсутствие прихвата, то на этом завершается (рис. 3, позиция 5) процедура прогнозирования для имеющихся КДП.

Если модель прогнозирует (рис. 3, позиция 4) прихват с указанием типа прихвата (рис. 3, позиция 3), тогда необходимо (рис. 3, позиция 7) скорректировать значения управляемых параметров из перечня КДП и повторять процедуру прогнозирования до тех пор, пока не достигается отрицательный прогноз на прихват. Тем не менее также необходимо обращать внимание на значение неуправляемых КДП и провести проверку правильности расчетов и определение этих параметров. Если изменениями значений управляемых параметров из перечня КДП не достигается отрицательного прогноза на прихват, то следует приступать к выработке мер по предупреждению или выводу скважины из прихватоопасного состояния [14].



Рис. 3. Алгоритм прогнозирования прихвата технологического инструмента по глубине ствола скважины [14]

Fig. 3. Algorithm of prediction technological tool sticking by the wellbore depth [14]

Предлагаемый способ прогнозирования прихвата технологического инструмента был реализован (воспроизведен) с использованием промысловых данных о прихватах ООО «НК ПАРИТЕТ», ООО «РУСГЕОСЕРВИС», а также архивных данных ВНИИКРнефть и ГУП «Таджикнефть». В результате процедур по прогнозированию были получены прогнозные значения по глубине ствола скважины, показывающие вероятность возникновения прихватов для каждого интервала бурения. Способ продемонстрировал прогнозирование прихватов с вероятностью 0,96.

Заключение

В заключение следует отметить, что в разработке модели и алгоритма прогнозирования прихвата технологического инструмента на основе четырехмодульной нейронной сети учитываются важные и универсальные факторы, влияющие на природу возникновения прихватов, в том числе типы горных пород, химические реагенты и добавки в качестве элементов входных данных. В результате предложенная модель позволяет прогнозировать возникновение и определять тип прихвата (на экспериментальных данных) с вероятностью 0,96, что более чем на 20 % превосходит по точности традиционные методы, которые рассматривались в работе [13].

Представленная в статье модель и алгоритм прогнозирования прихватов может применяться в буровых предприятиях в качестве вспомогательного инструмента для оценки риска возможного возникновения прихвата (по интервалам бурения) на стадии проектирования или в процессе бурения скважины, что позволит минимизировать риски их возникновения. Отличительная способность представленной модели состоит в том, что модель имеет возможность дообучаться и адаптироваться под имеющиеся в буровом предприятии условия (перечень импортных реагентов, химических добавок, геологических условий, а также инструментов и технологий бурения).

Список литературы

1. Muqem M.A., Weekse A.E., Al-Hajji A.A. Stuck Pipe Best Practices – A Challenging Approach to Reducing Stuck Pipe Costs // Presented at the SPE Saudi Arabia Section Technical Symposium and Exhibition. Al-Khobar, Saudi Arabia. 2012. P. 1–10. doi: 10.2118/160845-MS.
2. Alshaikh A.A., Albassam M.K., Al Gharbi S.H., Al-Yami A.S. Detection of Stuck Pipe Early Signs and the Way Toward Automation // Society of Petroleum Engineers. 2018. P. 1–10. doi: 10.2118/192975-MS.
3. Shahbazi K., Shahri M.P. The development of a window for stuck pipe prediction // Petroleum Science and Technology. 2012. Vol. 30, iss. 2. P. 176–192. doi: 10.1080/10916461003792302.
4. Miri R., Sampaio J.H.B., Afshar M., Lourenco A. Development of Artificial Neural Networks to Predict Differential Pipe Sticking in Iranian Offshore Oil Fields // Society of Petroleum Engineers. 2007. P. 1–15. doi: 10.2118/108500-MS.
5. Heinze L., Al-Baiyat I.A. Implementing Artificial Neural Networks and Support Vector Machines in Stuck Pipe Prediction // Society of Petroleum Engineers. Kuwait. 2012. P. 1–13. doi: 10.2118/163370-MS.
6. Jahanbakhshi R., Keshavarzi R., Jahanbakhshi R. Intelligent Prediction of Wellbore Stability in Oil And Gas Wells: An Artificial Neural Network Approach // Presented at the 46th U.S. Rock Mechanics. Geomechanics Symposium. Chicago, Illinois. 2012. P. 1–9. ARMA-2012-243.
7. 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). P. 173–183. doi: 10.5897/JPGGE2013.0166.
8. Shoraka S.A.R., Shadizadeh S.R., Shahri M.P. Prediction of Stuck Pipe in Iranian South Oil Fields Using Multivariate Statistical Analysis // Society of Petroleum Engineers. 2011. P. 1–10. doi: 10.2118/151076-MS.
9. 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. P. 1–15. SPE-120128.
10. Самотой А.К., Воротнюк О.В. Анализ априорных данных о факторах, действующих при прихвате колонны труб // Тр. ВНИИБТ. Борьба с осложнениями при бурении скважин. 1973. Вып. 7. С. 25–32.
11. Аветисов А.Г., Ахмадуллин М.М., Самотой А.К. Прогнозирование, предупреждение и ликвидация прихватов с использованием статистических методов // Тематический научно-технический обзор. М.: ВНИИОЭНГ. 1977. С. 62–73.
12. Мирзаджанзаде А.Х., Аветисов А.Г., Булатов А.И. и др. Методические указания по применению статистических методов в бурении нефтяных и газовых скважин. Краснодар, 1983. 72 с.
13. Кодиров Ш.Ш., Шестаков А.Л. Разработка искусственной нейронной сети для прогнозирования прихватов колонн буровых труб // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2019. Т. 19, № 3. С. 20–32. doi: 10.14529/ctcr190302
14. Пат. 2735794 Российская Федерация, МПК G06N 3/08 (2006.01). Способ прогнозирования прихватов буровых труб / А.Л. Шестаков, Ш.Ш. Кодиров; заявитель ЮУрГУ (НИУ). № 2020121477; заявл. 23.06.2020; опублик. 09.11.2020. 23 с.
15. Qodirov S., Shestakov A. Development of Artificial Neural Network for Predicting Drill Pipe Sticking in Real-Time Well Drilling Process // 2020 Global Smart Industry Conference (GloSIC). Chelyabinsk, Russia. 2020. P. 139–144. doi: 10.1109/GloSIC50886.2020.9267873.
16. Toreifi H., Rostami H., Manshad A.K. New method for prediction and solving the problem of drilling fluid loss using modular neural network and particle swarm optimization algorithm // Journal of Petroleum Exploration and Production Technology. 2014. Vol. 4. P. 371–379. doi: 10.1007/s13202-014-0102-5.
17. Shukla A., Tiwari R., Kala R. Modular Neural Networks. In: Towards Hybrid and Adaptive Computing. Studies in Computational Intelligence, vol. 307. Springer, Berlin, Heidelberg; 2010. P. 307–335. doi: 10.1007/978-3-642-14344-1_14.
18. Кошелева Н.Н. Корреляционный анализ и его применение для подсчета ранговой корреляции Спирмена // Актуальные проблемы гуманитарных и естественных наук. 2012. № 5. С. 23–26.

19. Francois Ch. *Deep Learning with Python*. Manning Publications, 2017. 386 p.
20. McMahan B., Rao D. *Natural Language Processing with PyTorch: Build Intelligent Language Applications Using Deep Learning*. O'Reilly Media, Inc., 2020. 337 p.
21. Wani M.A., Bhat F.A., Afzal S., Khan A.I. *Advances in Deep Learning. Studies in Big Data*, vol. 57. Springer Singapore, 2020. 159 p. doi: 10.1007/978-981-13-6794-6.

References

1. Muqem M.A., Weekse A.E., Al-Hajji A.A. Stuck Pipe Best Practices – A Challenging Approach to Reducing Stuck Pipe Costs. *Presented at the SPE Saudi Arabia Section Technical Symposium and Exhibition*. Al-Khobar, Saudi Arabia; 2012. P. 1–10. doi: 10.2118/160845-MS.
2. Alshaikh A.A., Albassam M.K., Al Gharbi S.H., Al-Yami A.S. Detection of Stuck Pipe Early Signs and the Way Toward Automation. *Society of Petroleum Engineers*; 2018. P. 1–10. doi: 10.2118/192975-MS.
3. Shahbazi K., Shahri M.P. The development of a window for stuck pipe prediction. *Petroleum Science and Technology*. 2012;30(2):176–192. doi: 10.1080/10916461003792302.
4. Miri R., Sampaio J.H.B., Afshar M., Lourenco A. Development of Artificial Neural Networks to Predict Differential Pipe Sticking in Iranian Offshore Oil Fields. *Society of Petroleum Engineers*; 2007. P. 1–15. doi: 10.2118/108500-MS
5. Heinze L., Al-Baiyat I.A. Implementing Artificial Neural Networks and Support Vector Machines in Stuck Pipe Prediction. *Society of Petroleum Engineers*. Kuwait; 2012. P. 1–13. doi: 10.2118/163370-MS.
6. Jahanbakhshi R., Keshavarzi R., Jahanbakhshi R. Intelligent Prediction of Wellbore Stability in Oil And Gas Wells: An Artificial Neural Network Approach. *Presented at the 46th U.S. Rock Mechanics. Geomechanics Symposium*. Chicago, Illinois; 2012. P. 1–9. ARMA-2012-243.
7. 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;4(7):173–183. doi: 10.5897/JPGE2013.0166.
8. Shoraka S.A.R., Shadizadeh S.R., Shahri M.P. Prediction of Stuck Pipe in Iranian South Oil Fields Using Multivariate Statistical Analysis. *Society of Petroleum Engineers*; 2011. P. 1–10. doi: 10.2118/151076-MS.
9. 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. P. 1–15. SPE-120128.
10. Samotoi A.K., Vorotnyuk O.V. [Analysis of a Priori Data on the Factors Affecting the Sticking of the Pipe Column]. *Trudy VNIIBT. Bor'ba s oslozhneniyami pri burenii skvazhin*. 1973;7:25–32. (In Russ.)
11. Avetisov A.G., Akhmadullin M.M., Samotoi A.K. [Prediction, Prevention and Liquidation of Sticking Pipe Using Statistical Methods]. *Tematicheskii nauchno-tekhnicheskii obzor*. Moscow, VNIIOENG; 1977. P. 62–73. (In Russ.)
12. Mirzadzhanzade A.Kh., Avetisov A.G., Bulatov A.I. et al. *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. 72 p.
13. 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;19(3):20–32. (In Russ.) doi: 10.14529/cter190302.
14. Shestakov A.L., Qodirov Sh.Sh. *Sposob prognozirovaniya prikhvatov buril'nykh trub* [Method for prediction of sticking of drilling pipes]. Patent RF, no. 2735794, 2020.
15. Qodirov S., Shestakov A. Development of Artificial Neural Network for Predicting Drill Pipe Sticking in Real-Time Well Drilling Process. In: *2020 Global Smart Industry Conference (GloSIC)*. Chelyabinsk, Russia; 2020. P. 139–144. doi: 10.1109/GloSIC50886.2020.9267873.
16. Toreifi H., Rostami H., Manshad A.K. New method for prediction and solving the problem of drilling fluid loss using modular neural network and particle swarm optimization algorithm. *Journal of Petroleum Exploration and Production Technology*. 2014;4:371–379. doi: 10.1007/s13202-014-0102-5.

17. Shukla A., Tiwari R., Kala R. Modular Neural Networks. In: Towards Hybrid and Adaptive Computing. Studies in Computational Intelligence, vol. 307. Springer, Berlin, Heidelberg; 2010. P. 307–335. doi: 10.1007/978-3-642-14344-1_14.
18. Kosheleva N.N. [Correlation analysis and its application for calculating Spearman's rank correlation]. *Actual problems of the humanities and natural sciences*. 2012;(5):23–26. (In Russ.)
19. Francois Ch. *Deep Learning with Python*. Manning Publications; 2017. 386 p.
20. McMahan B., Rao D. *Natural Language Processing with PyTorch: Build Intelligent Language Applications Using Deep Learning*. O'Reilly Media, Inc.; 2020. 337 p.
21. Wani M.A., Bhat F.A., Afzal S., Khan A.I. Advances in Deep Learning. Studies in Big Data, vol. 57. Springer Singapore; 2020. 159 p. doi: 10.1007/978-981-13-6794-6.

Информация об авторах

Кодиров Шахбоз Шарифович, аспирант кафедры информационно-измерительной техники, младший научный сотрудник международной лаборатории технической самодиагностики и самоконтроля приборов и систем, Южно-Уральский государственный университет, г. Челябинск, Россия; shahboztjk@mail.ru.

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

Information about the authors

Shahboz Sh. Qodirov, postgraduate student of the Department of Information-Measurement Systems, Junior researcher of International Laboratory for self-validating sensors, systems, and advanced instrumentation, South Ural State University, Chelyabinsk, Russia; shahboztjk@mail.ru.

Aleksandr L. Shestakov, Dr. Sci. (Eng.), Prof., Rector, South Ural State University, Chelyabinsk, Russia; admin@susu.ac.ru.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.

Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article.

The authors declare no conflicts of interests.

Статья поступила в редакцию 07.12.2021; одобрена после рецензирования 21.12.2021; принята к публикации 28.12.2021.

The article was submitted 07.12.2021; approved after reviewing 21.12.2021; accepted for publication 28.12.2021.