

УДК 681.518:622.276.58

## ОЦЕНКА ТЕХНИЧЕСКОГО СОСТОЯНИЯ ПРОМЫСЛОВОГО ОБОРУДОВАНИЯ С ПОМОЩЬЮ ЦИФРОВЫХ ТЕХНОЛОГИЙ

ГУМЕРОВА Велена Ильгизовна

магистрант

КОРОБКОВ Геннадий Евгеньевич

доктор технических наук, профессор

профессор кафедры «Транспорт и хранение нефти и газа»

Уфимский государственный нефтяной технический университет

г. Уфа, Россия

*В данном исследовании на основе примеров промышленного оборудования приведены различные варианты искусственных нейронных сетей, которые способны решить задачу распознавания образов на основе динамограммы. Проведен сравнительный анализ моделей нейронных сетей, а также проведено тестирование на основе обучающей выборки, которая состояла из 11 тысяч динамограмм, полученных в результате моделирования условий работы глубинного насоса. Подобная технология может быть предложена для оценки технического состояния трубопроводов, а также для других элементов промышленного оборудования.*

**Ключевые слова:** искусственный интеллект, штанговый глубинный насос, трубопровод, динамограмма, контроль, динамометрирование, нейронные сети.

На сегодняшний день большая часть нефтедобычи приходится на трудноизвлекаемые запасы, что требует применения новых и высокоэффективных технологий. В рамках реализации национальной программы цифровой экономики становится возможным широкое применение компьютерных систем, способных обращаться с большими базами данных «Big Data». Одним из инструментов здесь является использование нейросетевых технологий. Следует учесть, что текущий этап добычи нефти происходит в условиях, когда срок эксплуатации многих нефтяных месторождений в России приближается к концу, а оборудование, используемое для добычи, изношено, что увеличивает риск выхода из строя.

Ниже рассмотрим на примере самого распространенного элемента промышленного оборудования – штангового насоса, адаптацию нейросетевой технологии с целью оценки его технического состояния.

Современный промышленный сектор нефтегазовой промышленности нуждается во внедрении автоматизированных систем управления для его дальнейшего развития. Внедрение интеллектуальных систем дает ряд преимуществ. Это позволяет эффективно обрабатывать большие объемы информации, снижая «человеческий фактор» и вероятность возникновения различных ошибок

и сбоев при эксплуатации.

В России и по всему миру до 60-70% нефтедобывающих скважин используют штанговые глубинные насосы (ШГН). Однако, для специалистов, занимающихся мониторингом неисправностей оборудования, крайне важно знать, когда возможно ухудшение работы или отказ насосной установки, чтобы принять превентивные меры и избежать серьезных последствий. С развитием информационных технологий автоматизация производства стала одним из главных направлений развития нефтегазовой отрасли. Внедрение систем контроля за техническим состоянием оборудования стало необходимостью. Для контроля состояния ШГН используется динамометрирование, которое позволяет построить динамограмму – устьевую диаграмму, отображающую зависимость изменения нагрузки на устьевой шток при изменении ее хода.

В работе [5] были рассмотрены преимущества отечественных контроллеров перед зарубежными. Они оказались более доступными и имели приемлемый уровень цен.

Надежность работы ШГН зависит как от состояния оборудования, так и от управления им, поэтому важно исследовать и совершенствовать системы управления установками ШГН. Современные технологии позволяют автоматизировать процессы и контролировать работу насосов, что

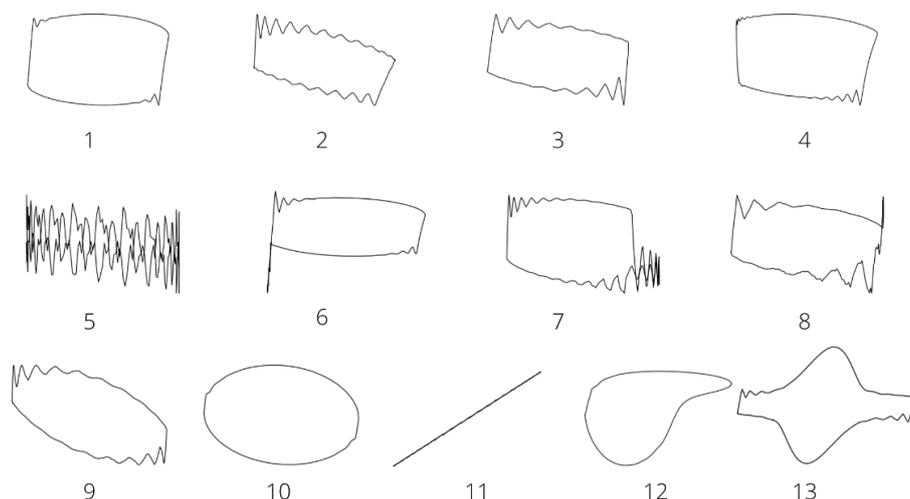
особенно актуально в условиях введения западных санкций против России.

Для улучшения системы контроля состояния ШГН были проведены исследования, связанные с применением нейросетевых технологий. В работе [1] использован метод опорных векторов для классификации динамограмм. В статье [2] рассмотрены возможности распознавания динамограмм с помощью глубоких нейронных сетей, а в статье [4] использованы глубокие сверточные нейронные сети для анализа данных.

Тестирование нейронных сетей в работах показало точность от 60 до 97%, что говорит о возможности использования этих методов в задаче контроля состояния ШГН. Однако, проблемой является определение наиболее подходящей модели нейронной сети и поиск модели, которая справится с задачей лучше, чем ранее существующие.

Для улучшения системы контроля состояния ШГН были исследованы возможности применения нейросетевых технологий. Однако, для построения моделей машинного обучения и нейросетевых моделей необходима обучающая выборка, объем которой должен быть очень велик. Это может представлять сложность для небольших компаний, для которых достаточно проблематично собрать такую выборку со всеми видами осложнений. Для решения этой задачи предлагается использовать математическое моделирование работы ШГН.

На рисунке 1 представлены теоретические динамограммы тринадцати состояний скважинного глубинного насоса. Данный набор, состоящий из 11 тысяч изображений, используется для задачи распознавания образов динамограмм средствами нейронных сетей.



1) нормальная работа насоса; 2) влияние пластового газа; 3) утечки в нагнетательном клапане; 4) утечки во всасывающем клапане; 5) обрыв штанг; 6) низкая посадка плунжера; 7) высокая посадка плунжера с выходом; 8) высокая посадка плунжера с ударом; 9) утечки в обоих клапанах; 10) эмульсия; 11) заклинивание в нижнем клапане; 12) отложение парафинов; 13) заедание плунжера.

*Рисунок 1. Плунжерные динамограммы ШГН*

В исследовании использовались три различных типа нейронных сетей: полносвязная, сверточная и сиамская модель. Перед обучением каждой модели нейронной сети были сформированы три выборки: обучающая, валидационная и тестовая.

Разработка архитектуры нейронной сети началась с параметров, доказавших свою эффективность при решении подобных задач [1; 2; 4]. Для полносвязной нейронной сети была выбрана многослойная модель персептрона с

тремя скрытыми слоями, чтобы получить оптимальные результаты. В случае сверточной и сиамской моделей была выбрана архитектура с тремя сверточными слоями.

В процессе обучения параметры и архитектуры были точно настроены, чтобы минимизировать функцию потерь и максимизировать точность.

На рисунке 2 представлены архитектуры моделей нейронных сетей, используемых в работе.

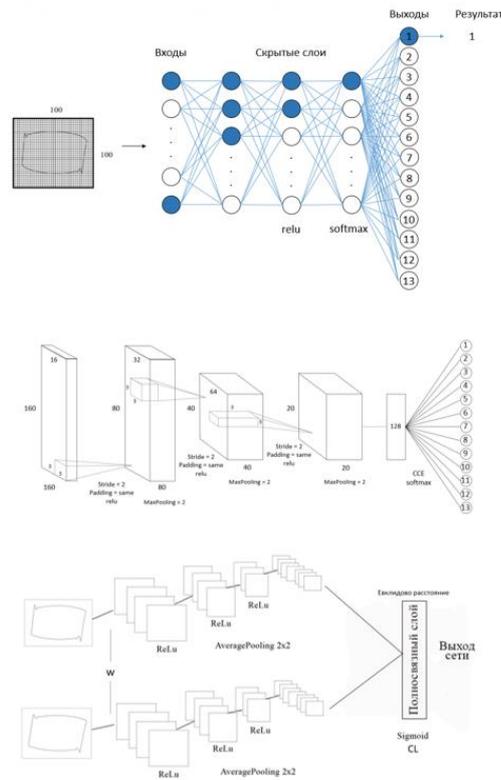


Рисунок 2. Архитектуры нейронных сетей

Во всех трех моделях использовались алгоритмы обучения обратного распространения, основанные на теории градиентного спуска, которые включают обновление весов многослойного персептрона путем вычисления градиентов с использованием цепного правила для дифференцирования сложных функций нескольких переменных.

Точность обучения полносвязной нейронной сети составила 8,12%, потери – 263,47%. Из-за большого количества нейронов во входном слое сеть быстро переобучилась и не справилась с задачей.

Точность обучения сверточной нейронной сети составила 96,28%, потери – 19,40%.

Точность обучения сиамской сверточной нейронной сети, согласно исследованию, составила 95,36%, потери – 4,52%.

Результаты тестирования нейронных сетей показали, что полносвязная нейронная сеть с большим количеством нейронов во входном слое имеет высокую вероятность переобучения и низкую точность. В связи с

этим, данная модель не рекомендуется к использованию в оперативном контроле состояния ШГН.

Чтобы повысить точность распознавания, рекомендуется использовать сверточные или сиамские нейронные сети, которые позволяют распознавать более сложные иерархии признаков и учитывать пространственные отношения на изображении. Кроме того, можно использовать другие функции активаций и потерь для улучшения точности моделей.

Результаты вышеприведенного анализа по выбору эффективной нейронной сети можно приложить и к оценке технического состояния промышленных трубопроводов с использованием многочисленных данных их технической диагностики (толщина стенки трубопровода, напряжения и деформации в стенке трубы, параметры электрохимической защиты и др.). Данная методика может быть использована и для других объектов промышленного оборудования.

**СПИСОК ЛИТЕРАТУРЫ**

1. Волков М.Г., Сильнов Д.В., Топольников А.С., Латыпов Б.М., Катермин А.В., Еникеев М.Р. Автоматизированная система интерпретации отклонений по лдинамограммам на основе средств машинного обучения при эксплуатации скважинных штанговых насосов // Нефтяное хозяйство. – 2021. – № 4. – С. 102-105. DOI: 10.24887/0028-2448-2021-4-102-105.
2. Данилов С.О. Идентификация осложнений и неисправностей погружного оборудования штанговых насосных установок с помощью нейронных сетей // Молодой ученый. – 2019. – № 15(253). – С. 17-22.
3. Малюгин А.А., Казунин Д.В. Расчет динамограмм штангового насоса в режиме реального времени // Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки. – 2017. – № 1. – С. 36-40.
4. Михайлов А.Г., Шубин С.С., Алферов А.В., Имашев Р.Н., Ямалиев В.У. Повышение эффективности диагностирования эксплуатации скважинных штанговых насосов с помощью сверточных нейронных сетей // Нефтяное хозяйство. – 2018. – № 9. – С. 122-126. DOI: 10.24887/0028-2448-2018-9-122-126.
5. Хакимьянов М.И. Повышение энергоэффективности и оптимизация режимов работы электропроводов в нефтедобывающей промышленности: дис. ... д-ра техн.наук. – Уфа: Изд-во УГНТУ, 2018. – 355 с.