

Методика автоматического распознавания неисправностей ШСНУ

ЧАЖАБАЕВА Маржан Маликовна, к.т.н., ассоциированный профессор, marzhan.chazhabayeva@yu.edu.kz, НАО «Каспийский университет технологий и инжиниринга им. Ш. Есенова», Казахстан, Актау, 32 микрорайон.

Аннотация. Одним из эффективных способов мониторинга является динамометрия. Динамограммы используются для диагностики и мониторинга работы ШСНУ. Предложен новый подход обнаружения и выявления отказов, неполадок в работе системы ШСНУ, исключая человеческий фактор. Предлагается использование дескрипторов Фурье для распознавания динамометрических карт и техники машинного обучения для классификации различных условий насоса. С помощью дескриптора Фурье можно спрогнозировать и диагностировать неисправности работы скважинного насоса. Эти дескрипторы упрощают, нормализуют и хорошо описывают каждую карту. Предложенная методика обучается с использованием данных реальных динамометрических карт.

Ключевые слова: штанговая глубинная насосная установка (ШСНУ), мониторинг, отказ, неполадки, динамометрическая карта, динамограмма, дескрипторы Фурье, техника машинного обучения, модель, алгоритм распознавания, анализ данных.

Введение. В настоящее время падение спроса на топливо из-за пандемии вызвало кризис в нефтяной отрасли. Нефтедобывающие страны, Казахстан в том числе, вынуждены сократить добычу нефти, в целях недопущения падения цен на нефть. Это неизменно приведёт к приостановлению или полной остановке эксплуатации, приблизительно, 30% скважин от их общего количества. Так как, 80% фонда скважин Казахстана составляет штанговая скважинная насосная установка (ШСНУ), при остановке 30% скважин, будет остро стоять вопрос нормального, бесперебойного функционирования эксплуатируемых скважин, в частности, их оборудования и установок.

Существует множество способов повышения эффективности работы и продления срока службы ШСНУ, важным из которых является своевременное диагностирование, мониторинг работы ШСНУ. Нужно разработать методики, которые позволят спрогнозировать и диагностировать неисправности работы скважинного насоса.

Методы исследования. Одним из эффективных способов мониторинга является динамометрия, построение динамограммы, которая даёт полную информацию о состоянии подземного оборудования и позволяет оценить режим эксплуатации скважины [1].

Для обучения модели используется подход контролируемого обучения. Полученная модель может предсказывать вероятность некоторых неблагоприятных условий для работы насоса и классифицировать их.

Для анализа данных обучения будут исполь-

зоваться контролируемые алгоритмы обучения. Эти алгоритмы создают предполагаемую функцию, способную отображать обучающие примеры. Кроме того, им будет разрешено правильно определять метки классов для невидимых экземпляров. Это требуется, чтобы алгоритм обучения обобщал данные обучения в невидимые ситуации «разумным» образом.

В работе модели применяется Knowledge Discovery in Databases (KDD) – это процесс обнаружения или поиска полезных данных. Использование KDD показывает: 1 – правильный выбор входных данных, 2 – как извлечь признаки, 3 – использование правильного классификатора и 4 – оценку результатов. На рисунке 1 показаны этапы KDD. В этой работе скважинные условия рассматриваются как зависимые переменные. При этом данные динамометрических карт рассматриваются как независимые переменные [2].

Динамограммы используются для диагностики и мониторинга работы ШСНУ. Традиционно диагностика с использованием динамограмм штангового насоса проводится с помощью экспертов в данной отрасли. Результаты анализа и интерпретации динамограмм напрямую зависят от знаний и опыта экспертов в данной отрасли. Имеет место огромное влияние человеческого фактора на анализ ШСНУ.

Контроль всех насосов на месторождении экспертами требует больших временных и финансовых затрат. Эти затраты относительно высоки по сравнению со стоимостью использования автоматической системы диагностики. Использование




Рисунок 1 – Этапы KDD (поиск полезных данных в БД)

машинного обучения в автоматической диагностике насосной установки повышает операционную эффективность, позволяет быстрее и более точно выявлять неполадки в работе техники.

Главной проблемой процесса выявления неисправностей работы штанговых насосов является визуальная интерпретация полученной информации. В большинстве случаев сложность визуальной интерпретации зависит от нескольких факторов. Эти факторы включают в себя поведение самой системы, что приводит к похожим формам полученных динамограмм. Кроме этого, возникшая проблема при анализе динамометрической карты может быть за пределами знаний и опыта эксперта, который проводит анализ.

Предлагается новый подход обнаружения и выявления отказов, неполадок в работе системы ШСНУ, исключающий человеческий фактор (возможные ошибки при неправильной визуальной интерпретации динамограмм).

Основная идея работы заключается в использовании искусственной нейронной сети (ИНС) для распознавания и классификации образов динамометрических карт ШСНУ. Этот подход включает использование дескрипторов Фурье для распознавания динамометрических карт, затем использует технику машинного обучения для классификации различных условий насоса. Модель, изучая закономерности на основе введенных данных, распознаёт условия работы скважинного насоса. Эти данные предварительно вводятся экспертами в анализе динамограмм.

Этот подход эффективен по двум направлениям. Во-первых, такой подход позволяет извлечь дескрипторы Фурье, которые используются в аналитическом решении волнового уравнения штангового насоса. Во-вторых, он нацелен на обнаружение 13 различных состояний динамометрических карт с большим набором данных, собранных со всех скважин на месторождении.

Предлагается разделить алгоритм распознавания на 4 этапа. Каждый этап имеет значимое влияние на решение каждого отдельного случая распознавания и охватывает все возможные неполадки, [3].

Предлагаемые 4 этапа:

- сбор и анализ данных;
- функция извлечения;
- схема классификации;
- тестирование и оценка.

Методика включает в себя следующие процедуры, которые охватывают все перечисленные 4

этапа:

- Рассмотрение предыдущих подходов извлечения свойств динамометрических карт;
- Обзор предыдущих методов классификации;
- Алгоритм извлечения свойств, который дает наилучшие результаты;
- Сбор реальных динамометрических карт, классифицированных экспертами;
- Подготовка этих данных с использованием алгоритма извлечения свойств;
- Использование контролируемых алгоритмов машинного обучения;
- Предложение конкретной модели на основе ошибки валидации;
- Оценка этой модели с учетом различных условий ШСНУ;
- Тестирование разработанной модели.

На первом этапе следует принять решение о количестве переменных и какие переменные следует использовать.

Выбор начальных переменных должен проводиться экспертами в этой области. Важны все переменные, которые могут оказать влияние на работу ШСНУ. На данном этапе важен опыт работы и знания экспертов для представления о том, какие данные имеют значимость.

Используемые начальные переменные: данные динамометрических карт, заполнение насоса, крутящий момент, нагрузка на полированный шток, общий расход жидкости, длина хода плунжера (поршня) и т.д.

Важным условием на данном этапе является проведение динамометрии скважины. Динамометрия является мощным инструментом для мониторинга системы ШСНУ в целом. Анализ результатов динамометрии будет основным переменным для данной методики.

Извлечение функций является одним из важных элементов для успешного распознавания признаков динамометрических карт. По определению, признак – это заметная часть или характеристика объекта, для того чтобы отличить его. Извлечение признаков – это процесс создания функций, [4].

Предлагается преобразовать входные данные в сокращенный набор функций или вектор объектов. Этот процесс называется выбором функции. Ожидается, что выбранные функции будут содержать соответствующую информацию из входных данных. Это облегчает последующие этапы обучения.

Разрабатываемая по данной методике модель

выполняет преобразование данных карты динамометра (x, y). Это преобразование превращает карту из пространства наблюдения в n -мерный вектор. Полученный вектор включает в себя характеристические эллиптические дескрипторы Фурье. Эти дескрипторы упрощают, нормализуют и хорошо описывают каждую карту.

Эллиптические функции Фурье были разработаны Кулем и Джардиной (1982) [5]. Они представили новый подход к старой проблеме численной характеристики сложных форм.

По существу, эллиптические дескрипторы Фурье представляют собой параметрическое решение проблемы численного определения сложных форм. Двумерный контур (x, y) можно разделить на две кривые. Разделение выполняется путем построения функции контура третьей переменной (t). Первая кривая представляет собой график зависимости оси X от карты (t). Вторая кривая представляет собой график зависимости оси Y от карты (t). Затем получена пара уравнений как функция третьей переменной (t). Параметры этих двух уравнений используются в векторе признаков.

Чем ближе расстояние между наблюдаемыми точками, тем точнее изображение карты. Оси X и Y могут быть определены как функция времени (Третья переменная). Эти новые функции являются однозначными и периодическими. Поэтому они могут быть снабжены функциями Фурье [6].

На рисунке 2 приведен пример реальной динамометрической карты стержневого насоса. Рассмотрим значения координат x и y , нанесенные на новую горизонтальную «ось x », которая была обозначена как «ось t » (ось времени). Эти x и y «проекции» показаны на рисунках 3 и 4.

Изучение этих цифр показывает, что они всегда будут однозначными и периодическими. Подчеркнуто, что на рисунках 3 и 4 установлена функция Фурье [7]. Одним из преимуществ ис-

пользования этого алгоритма является то, что карта может быть воссоздана. x – координаты и координаты y , которые были вычислены отдельно, могут «воссоединиться» с этими координатами (для идентичных значений t). Затем ожидаемая форма воссоздается.

По итогу, эллиптические дескрипторы Фурье представляют собой параметрическое решение. Это предполагает вывод пары уравнений. Эти два уравнения являются функцией третьей переменной ($X(t)$ and $Y(t)$), как показано в уравнении (1) [8].

$$\begin{pmatrix} X(t) \\ Y(t) \end{pmatrix} = \sum_{n=0}^k \begin{pmatrix} a_n b_n \\ c_n d_n \end{pmatrix} \begin{pmatrix} \sin\left(\frac{2n\pi t}{T}\right) \\ \cos\left(\frac{2n\pi t}{T}\right) \end{pmatrix}, \quad (1)$$

где t – третья предполагаемая переменная, n – номер гармоники, a_n, b_n, c_n, d_n – коэффициенты Фурье, соответствующие n th-гармонике, T – период (сумма всех t приращений).

Шаг первый: извлечение границы

Файл карты представлен в виде списка (x, y) позиций всей карты. x_p и y_p определяются как суммирование связей между каждым последующим пунктом. Сумма связей между точками может быть рассчитана из уравнений:

$$x_p = \sum_{i=1}^p \Delta x_i, \quad (2)$$

$$y_p = \sum_{i=1}^p \Delta y_i, \quad (3)$$

где p – индекс звена цепи, x_p – суммирование связей по оси x , y_p – суммирование связей по оси y .

Шаг второй: определение третьего параметра

Длина ссылок называется «время». Вклад любой диагональной связи составляет $\sqrt{x^2 + y^2}$. «Время» ссылки пути – это сумма всех времен предыдущих ссылок, как показано в уравнении 4.




Рисунок 2 – Пример реальной динамометрической карты




Рисунок 3 – Проекция оси x рисунка 2 на третью переменную t




Рисунок 4 – Проекция оси y рисунка 2 на третью переменную t

$$t_p = \sum_{i=1}^p \Delta t_i, \quad (4)$$

где p – индекс звена цепи, t_p – длина цепи в звене пути.

Шаг третий: дескрипторы Фурье

Решается уравнение (1), чтобы получить a_n и b_n , как показано в уравнениях 5 и 6:

$$a_n = \frac{T}{2n^2 \pi^2} \sum_{i=1}^p \frac{\Delta x_p}{\Delta t_p} \left[\cos\left(\frac{2n\pi t_p}{T}\right) - \cos\left(\frac{2n\pi t_{p-1}}{T}\right) \right], \quad (5)$$

$$b_n = \frac{T}{2n^2 \pi^2} \sum_{i=1}^p \frac{\Delta y_p}{\Delta t_p} \left[\sin\left(\frac{2n\pi t_p}{T}\right) - \sin\left(\frac{2n\pi t_{p-1}}{T}\right) \right], \quad (6)$$

где n – номер гармоники, a_n , b_n – коэффициенты Фурье, соответствующие n th-гармонике, T – период (сумма всех t приращений), k – общее количество ссылок, p – индекс звена цепи, x_p – суммирование связей по оси x , t_p – длина цепи в звене пути.

Те же процедуры применяются для оси y . Соответственно, c_n и d_n идентифицированы, как показано в уравнениях 7 и 8.

$$c_n = \frac{T}{2n^2 \pi^2} \sum_{i=1}^p \frac{\Delta y_p}{\Delta t_p} \left[\cos\left(\frac{2n\pi t_p}{T}\right) - \cos\left(\frac{2n\pi t_{p-1}}{T}\right) \right], \quad (7)$$

$$d_n = \frac{T}{2n^2 \pi^2} \sum_{i=1}^p \frac{\Delta y_p}{\Delta t_p} \left[\sin\left(\frac{2n\pi t_p}{T}\right) - \sin\left(\frac{2n\pi t_{p-1}}{T}\right) \right], \quad (8)$$

где n – номер гармоники, c_n , d_n – коэффициенты Фурье, соответствующие n th-гармонике, T : период (сумма всех t приращений), k – общее количество звеньев цепи, p – индекс звена цепи, y_p – суммирование связей по оси y , t_p – длина цепи в звене пути.

Шаг четвертый: входной вектор машинного обучения

Следует подчеркнуть, что входными параметрами являются 15 эллиптических дескрипторов

Фурье, которые обеспечивают нормализованный набор коэффициентов a_n, b_n, c_n и d_n . Эти коэффициенты являются инвариантами вращения, перемещения и масштаба. Следовательно, создается матрица значений $[15 \times 4]$. Первый коэффициент относится к центру входной формы. Поэтому это можно игнорировать. Остаются остальные 59 коэффициентов EFD. Эти 59 дескрипторов могут быть использованы для сравнения форм.

Следовательно, вектор признаков $\chi = (a_2, b_2, c_2, d_2, \dots, a_{15}, b_{15}, c_{15}, d_{15})$ может быть построен и использован в качестве входных данных алгоритма

классификации.

Заключение. Разрабатываемая по данной методике модель выполняет преобразование данных карты динамометра (x, y) . Это преобразование превращает карту из пространства наблюдения в n -мерный вектор. Полученный вектор включает в себя характеристические эллиптические дескрипторы Фурье. Эти дескрипторы упрощают, нормализуют и хорошо описывают каждую карту. Предложенная методика обучается с использованием данных реальных динамометрических карт.

СПИСОК ЛИТЕРАТУРЫ

1. Молчанов А.Г. Пути дальнейшего совершенствования штанговых скважинных насосных установок // Специализированный журнал «Бурение и нефть». Москва. 2014. – С. 2-4.
2. Бубнов М.В., Зюзев А.М. Средства диагностирования оборудования установок штанговых глубинных насосов / УралЭНИН, ФГАОУ ВПО «УрФУ» – Конференция молодых ученых, 2016. – С. 2-3.
3. Andrew, N., 2015, «Lecture Notes on Machine Learning, Dimensionality Reduction», Vol. 10.
4. Anthony Allison (): Accurate Load & Position Measurement Is Critical to Quality Dynamometer Analysis. Weatherford, updated on 9/18/2015, checked on 1/22/2019. – 2015.
5. Bottone, S., Lee, Y., and O'Sullivan, M., «Failure Prediction and Diagnosis for Satellite Monitoring Systems Using Bayesian Network», SPIE 6736, Unmanned Sensors and Sensor Networks IV, 5 October., 2008.
6. Oshi, Prateek, Python. Real world machine learning: learn to solve challenging data science problems by building powerful machine learning models using Python / Prateek Joshi [and four others]. Birmingham, UK: Packt Publishing. – 2016.
7. Ramez Maher Aziz Zaky Abdalla, «AUTOMATIC WELL FAILURE ANALYSIS FOR THE SUCKER ROD PUMPING SYSTEMS», Faculty of engineering, CAIRO UNIVERSITY GIZA, EGYPT, 2018.

ШТҚ ақаулықтарын автоматты түрде тану әдісі

ЧАЖАБАЕВА Маржан Маликовна, т.ғ.к., қауымдастырылған профессор, marzhan.chazhabayeva@yu.edu.kz, «Ш. Есенов атындағы Каспий технологиялар және инжиниринг университеті» КеАҚ, Қазақстан, Ақтау, 32 шағын аудан.

Аңдатпа. Мониторингтің тиімді әдістерінің бірі-динамометрия. Динамограммалар ШТҚ жұмысын диагностикалау және бақылау үшін қолданылады. Адам факторын болдырмайтын ШТҚ жүйесінің жұмысындағы ақаулықтарды, істен шығуларды анықтаудың жаңа тәсілі ұсынылады. Фурье дескрипторларын динамометриялық карталарды тану үшін және сорғының әртүрлі жағдайларын жіктеу үшін машиналық оқыту техникасын қолдану ұсынылады. Фурье дескрипторының көмегімен ұңғыма сорғысының ақауларын болжауға және диагноз қоюға болады. Бұл дескрипторлар әр картаны жеңілдетеді, қалыпқа келтіреді және жақсы сипаттайды. Ұсынылған әдіс нақты динамометриялық карталардың деректерін қолдана отырып оқытылады.

Кілт сөздер: штангалық тереңдік сорғы қондырғысы (ШТҚ), мониторинг, істен шығу, ақаулар, динамометриялық карта, динамограмма, Фурье дескрипторлары, машиналық оқыту техникасы, моделі, тану алгоритмі, деректерді талдау.

The Technique of Automatic Fault Recognition of the RDPU

CHAZHABAYEVA Marzhan, Cand. of Tech. Sci., Associate Professor, marzhan.chazhabayeva@yu.edu.kz, NCJSC «Sh. Yessenov Caspian University of Technology and Engineering», Kazakhstan, Aktau, Microdistrict 32.

Abstract. One of the most effective ways of monitoring is dynamometry. Dynamograms are used to diagnose and monitor the operation of the RDPU. A new approach is proposed for detecting and identifying failures, malfunctions in the operation of the RDPU system, excluding the human factor. The use of Fourier descriptors for the recognition of dynamometric maps and machine learning techniques for the classification of various pump conditions is proposed. With the help of the Fourier descriptor, it is possible to predict and diagnose malfunctions of the downhole pump. These descriptors simplify, normalize, and describe each map well. The proposed method is trained using data from real dynamometric maps.

Keywords: rod deep pumping unit (RDPU), monitoring, failure, malfunctions, dynamometric map, dynamogram, Fourier descriptors, machine learning technique, model, recognition algorithm, data analysis.

REFERENCES

1. Molchanov A.G. Puti dal'nejshego sovershenstvovaniya shtangovyh skvazhinnyh nasosnyh ustanovok // Specializirovannyj zhurnal «Burenie i neft'». Moscow. 2014. – pp. 2-4.
2. Bubnov M.V., Zjuzev A.M. Sredstva diagnostirovaniya oborudovaniya ustanovok shtangovyh glubinyh nasosov / UralJeNIN, FGAOU VPO «UrFU» – Konferencija molodyh uchenyh, 2016 – pp. 2-3.
3. Andrew, N., 2015, «Lecture Notes on Machine Learning, Dimensionality Reduction», Vol. 10.
4. Anthony Allison (): Accurate Load & Position Measurement Is Critical to Quality Dynamometer Analysis. Weatherford, updated on 9/18/2015, checked on 1/22/2019. – 2015.
5. Bottone, S., Lee, Y., and O'Sullivan, M., «Failure Prediction and Diagnosis for Satellite Monitoring Systems Using Bayesian Network», SPIE 6736, Unmanned Sensors and Sensor Networks IV, 5 October., 2008.
6. Oshi, Prateek, Python. Real world machine learning: learn to solve challenging data science problems by building powerful machine learning models using Python / Prateek Joshi [and four others]. Birmingham, UK: Packt Publishing. – 2016.
7. Ramez Maher Aziz Zaky Abdalla, «AUTOMATIC WELL FAILURE ANALYSIS FOR THE SUCKER ROD PUMPING SYSTEMS», Faculty of engineering, CAIRO UNIVERSITY GIZA, EGYPT, 2018.