

ФОРМИРОВАНИЕ ХАРАКТЕРИСТИК ЭЛЕМЕНТА СТАНЦИИ НА ОСНОВЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

FORMATION OF STATION ELEMENT CHARACTERISTICS ON THE BASIS OF MACHINE LEARNING METHODS

**S. Olimpiev
A. Neklyudov**

Summary. Purpose: Deviations of equipment operation parameters can lead to a decrease in the efficiency of individual technological elements of the plant. In this regard, the task of determining correct parameters of equipment operation remains quite important in the field of power engineering. The article is devoted to the study of the approach to the formation of the characteristic surface of the plant element using the machine learning method. The article considers the algorithm for building the characteristic surface of the sharp steam flow rate parameter for a heat recovery turbine, and also evaluates the quality of the developed model in accordance with the accuracy indicators. *Methods:* The linear regression method is a statistical linear regression method, which is used to construct a linear model describing the relationship between a dependent variable and a set of other independent variables. *Results:* Algorithm for constructing the characteristic surface of the station element, calculation of the accuracy indicators of the model. *Conclusions of the study:* The approach based on the method of linear regression for the construction of the characteristic surface of the station element is shown. The results of the work can be applied in studies related to the process of updating the equipment parameters of station elements.

Keywords: characteristic area, regression analysis, machine learning, turbine, thermal power plant.

Олимпиев Сергей Александрович

Аспирант, Национальный исследовательский университет, Московский Энергетический Институт
OlimpiyevSA@mpei.ru

Неклюдов Алексей Васильевич

кандидат технических наук, доцент,
Национальный исследовательский университет,
Московский Энергетический Институт
NeklyudovAIV@mpei.ru

Аннотация. Цель: Отклонения параметров работы оборудования могут приводить к снижению эффективности работы отдельных технологических элементов станции. В связи с этим, в области энергетики остается достаточно важной задача определения корректных параметров работы оборудования. Статья посвящена исследованию подхода к формированию характеристической поверхности элемента станции с использованием метода машинного обучения. В статье рассмотрен алгоритм построения поверхности характеристик параметра расхода острого пара для теплофикационной турбины, а также выполнена оценка качества разработанной модели в соответствии с показателями точности. *Методы:* Метод линейной регрессии — статистический метод линейной регрессии, который используется для построения линейной модели, описывающей зависимость между зависимой и множеством других независимых переменных. *Результаты:* Алгоритм построения характеристической поверхности элемента станции, расчет показателей точности модели. *Выводы исследования:* Показан подход, основанный на методе линейной регрессии, для построения характеристической поверхности элемента станции. Результаты работы могут быть применимы в исследованиях, связанных с процессом актуализации параметров оборудования элементов станции.

Ключевые слова: характеристическая поверхность, регрессионный анализ, линейная регрессия, машинное обучение, турбина, тепловая электростанция.

В современном мире быстрые темпы технологического процесса сопровождаются ростом сложности задач и объемов обрабатываемых данных. Методы машинного обучения становятся незаменимым инструментом для поддержания конкурентоспособности и эффективности в различных отраслях промышленности [5].

В области промышленной автоматизации и энергетики методы машинного обучения широко применяются для актуализации параметров оборудования станции. Актуализация параметров оборудования включает в себя регулярный анализ и обновление характеристик оборудования на основе текущих условий эксплуатации и технологических данных. Это необходимо для поддержания оптимальной работы оборудования и предотвращения преждевременного износа или выхода из строя.

Методы машинного обучения позволяют создавать модели, которые могут анализировать большие объемы данных, поступающие с приборов учета и систем мониторинга оборудования. Эти модели могут обнаруживать изменения в поведении оборудования и корректировать его параметры в соответствии с новыми технологическими условиями [6].

Характеристическая поверхность элемента станции играет важную роль в процессе актуализации параметров оборудования. Она служит основой для оценки текущего состояния оборудования и сравнения его с ожидаемыми характеристиками. Анализ характеристик позволяет выявить отклонения от нормального режима работы и скорректировать параметры оборудования таким образом, чтобы вернуть его в оптимальный рабочий диапазон.

При построении поверхности характеристик исследуемым элементом станции может выступать турбинная установка, котлоагрегат, подогреватели низкого или высокого давления, а также другие значимые элементы станции. Характеристики элемента станции могут описывать зависимости мощности, расхода теплоносителя, КПД и других ключевых параметров от давления и температуры пара [1-2].

Для построения поверхности характеристик элемента станции могут использоваться различные методы машинного обучения. Предлагается подход к формированию поверхности характеристик элемента станции с применением регрессионного анализа. Основная идея регрессии заключается в поиске уравнения, которое наилучшим образом описывает связь между переменными [8].

Научные исследования в области промышленной автоматизации и энергетики с использованием регрессионного метода машинного обучения активно ведутся и в настоящее время. Проводятся исследования технико-экономических показателей тепловых электростанций с применением регрессионного анализа [3]. С использованием линейной регрессии исследуются подходы к прогнозированию генерации тепловой электростанции [9].

В рамках данного исследования, в виде элемента станции рассматривается теплофикационная турбинная установка. Исследуемой характеристикой турбинной установки является расход острого пара D_0 . Характеристическая поверхность строится для параметра расхода острого пара D_0 и проводится анализ отклонений параметра.

Моделирование проводится в среде разработки Jupiter Notebook на языке программирования Python с использованием библиотек Pandas и NumPy для обработки и анализа данных, Plotly и Matplotlib для формирования графической поверхности, Scipy и Sklearn для применения методов машинного обучения.

Разработана специальная функция Data_Fit. В теле функции воспроизводится алгоритм построения характеристической поверхности элемента станции. Алгоритм построения характеристической поверхности состоит из следующих этапов: подготовка исходных данных, создание модели, предсказание модели, показатели точности, построение графической поверхности, фильтрация и вывод данных.

На вход функции подается определенная структура данных DataFrame. В общем виде DataFrame можно представить как таблицу с параметрами, характеризующие элемент станции, в несколько рядов. На первом этапе

производится обработка входной таблицы с параметрами и выполняется ряд операций для подготовки данных.

После обработки входной таблицы с параметрами происходит создание экземпляра класса LinearRegression. В данном исследовании предполагается, что зависимость параметра технологического элемента линейна по отношению к другим параметрам. Класс LinearRegression реализует метод линейной регрессии, который используется для построения линейной модели, основанной на минимизации среднеквадратичного отклонения.

Происходит обучение модели линейной регрессии на основе подготовленных данных. Обучение модели происходит с помощью метода fit. В рамках метода fit создается линейное уравнение вида 1.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (1)$$

Где y — зависимая переменная, x_i — независимые переменные, β_i — коэффициенты линейной регрессии, ε — случайная ошибка.

Данные представляются в виде матричной формы. Для нахождения коэффициентов линейной регрессии решается система нормальных уравнений, представленная выражением 2.

$$X^T \cdot X \cdot \beta = X^T \cdot F \quad (2)$$

Где X — матрица набора независимых значений, F — матрица набора зависимых значений, β — искомый вектор коэффициентов линейной регрессии.

В результате выполнения метода fit, выводятся коэффициенты линейной регрессии. Коэффициенты являются оценками параметров линейной регрессии и определяют вклад каждой независимой переменной в предсказание зависимой переменной. Также, выводится значение свободного члена, который характеризует точку пересечения с осью Y . Точка пересечения с осью Y определяет смещение модели относительно оси Y .

Выполняется предсказание значений на основе набора данных с независимыми параметрами. Выполнение предсказания значений происходит с помощью метода predict. Предсказание модели осуществляется с помощью умножения каждой строки матрицы входного набора данных на вектор коэффициентов линейной регрессии с добавлением свободного члена. Предсказание для нового набора данных осуществляется по выражению 3.

$$y_{predict} = \beta_0 + \beta_1 x_{predict 1} + \beta_2 x_{predict 2} + \dots + \beta_n x_{predict n} \quad (3)$$

Где $y_{predict}$ — предсказанное значение зависимой переменной для нового набора данных, β_0 — свободный

член, $\beta_1, \beta_2, \dots, \beta_n$ — коэффициенты линейной регрессии для соответствующих независимых переменных, $x_{predict\ 1}, x_{predict\ 2}, \dots, x_{predict\ n}$ — набор независимых значений, на которых проводится предсказание. Результатом предсказания является вектор предсказанных значений.

Для оценки качества модели и принятия решения о ее пригодности используются показатели точности. Показатели точности предоставляют количественную информацию, на основе которой делается вывод о качестве модели [4]. Вычисляются остаточные ошибки, как разница между исходными и предсказанными значениями. На основе результатов остаточных ошибок вычисляется стандартное отклонение. Вычисляются следующие показатели точности: показатель средней абсолютной ошибки MAE, показатель средней квадратичной ошибки MSE, показатель средней абсолютной ошибки в процентах MAPE, показатель средней процентной ошибки MPE.

В ходе этапа построения графической поверхности создается пространство для отрисовки графика. Добавляются графические приближения с предсказанными значениями, исходными значениями, остаточными ошибками, положительными и отрицательными пороговыми значениями отклонений при помощи метода `add_trace`. После создания поверхности и добавления графических приближений, полученная поверхность с характеристиками объекта выводится с помощью метода `show`.

Результат этапа построения графической поверхности выводит характеристическую поверхность, отображенную на рисунке 1.

Графическое приближение, выделенное красным цветом, характеризует исходные значения расхода D_0 во временном интервале 3 года, начиная с января 2021 года и заканчивая январем 2024 года. Графическое приближение, выделенное синим цветом, характеризует предсказанные значения расхода D_0 в аналогичном временном интервале. В нижней части графической поверхности отображается приближение, выделенное зеленым цветом, которое характеризует показатель остаточного отклонения между исходными и предсказанными значениями. Остаточное отклонение анализируется в соответствии с положительной и отрицательной границами доверительного интервала. Границы положительного и отрицательного интервалов характеризуются соответственно графическими приближениями фиолетового и желтого цветов.

Совместно с характеристической поверхностью, выводятся показатели коэффициентов в виде массива и свободный член линейной регрессии, а также статистические показатели модели. Для наглядного представления статистические показатели вынесены в таблицу 1.

Таблица 1.

Статистические показатели модели

Показатель	Значение
Стандартное отклонение	8,361540780694083
Средняя абсолютная ошибка (MAE)	6,88265842956903
Средняя квадратичная ошибка (MSE)	69,90871891172439
Средняя абсолютная процентная ошибка (MAPE)	1,7276722286033706
Средняя процентная ошибка (MPE)	-0,023509917905001634

коэффициенты [4.41863319e+00 2.32703679e-01 7.86016432e+01 -3.21864639e+01
 -3.99680289e-14 -1.83844834e+00 5.46152821e-02]
 intercept 187.1310507565795
 сигма : 8.361540780694083 MAE: 6.88265842956903 MSE: 69.90871891172439 MPE: (%) -0.023509917905001634 MAPE (%): 1.7276722286033706

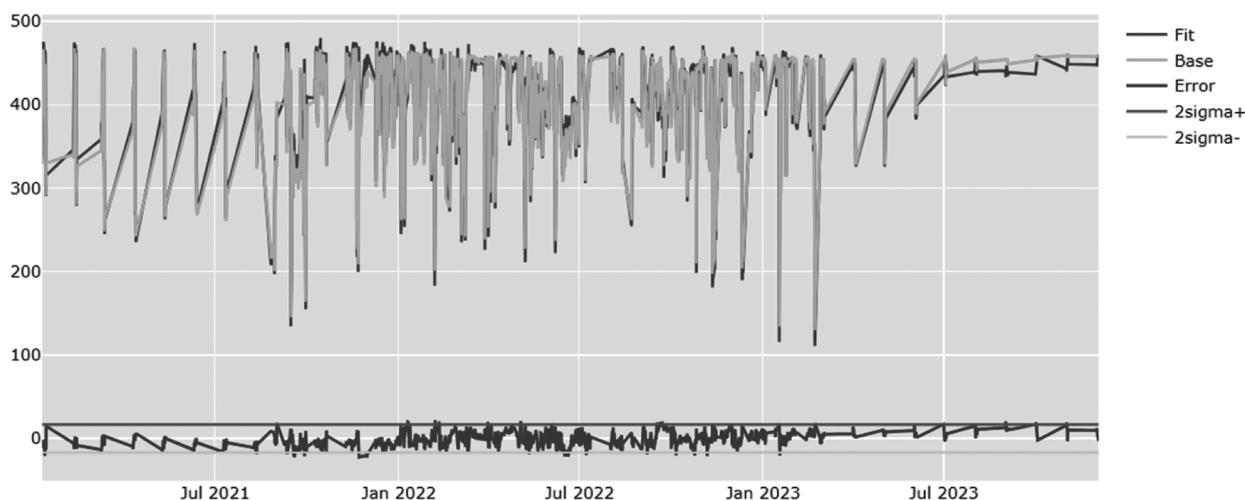


Рис. 1. Характеристическая поверхность параметра расхода острого пара D_0

В результате, полученная модель демонстрирует хорошую точность, учитывая небольшую среднюю абсолютную ошибку (MAE) и низкую среднюю абсолютную процентную ошибку (MAPE). Однако высокое значение стандартной ошибки и средней квадратичной ошибки (MSE) показывают, что модель подвержена значительным колебаниям в своих предсказаниях и склонна допускать крупные ошибки. Отрицательная средняя процентная ошибка (MPE) указывает на отрицательное направление систематической ошибки, что говорит о тенденции к недооцениванию истинных значений.

В данной работе был предложен подход к формированию характеристической поверхности элемента станции на основе линейной регрессии. В результате исследования была построена характеристическая поверхность расхода острого пара D_0 для теплофикационной турбины и проведена оценка показателей точности модели. На основе предложенной графической поверхности возможно проводить анализ других параметров. Проведение такого анализа способствует выявлению отклонений от нормального режима работы и корректировке параметров оборудования для возвращения в оптимальный режим работы.

ЛИТЕРАТУРА

1. Андрияшин А.В. Решение задачи оптимизации режимов работы комбинированных теплоэнергетических систем в зависимости от выбранного метода / А.В. Андрияшин, Э.К. Аракелян, А.В. Неклюдов, Н.С. Долбикова, Ю.Ю. Ягупова // Киберфизические системы: моделирование и промышленное применение. 2022. С. 107–115.
2. Аракелян Э.К. Методические основы оптимального распределения нагрузки на тепловой электростанции со сложным составом оборудования с учетом требований рынка / Э.К. Аракелян, А.В. Андрияшин, А.В. Неклюдов, Ю.Ю. Ягупова, С.В. Мезин // Журнал «Физика»: Серия конференций. 2021.
3. Васильев П.В. Использование цифровых технологий для расчета ТЭП тепловых электростанций / П.В. Васильев, Ю.Б. Гончаренко, А.В. Лесных, О.Г. Мочалов // Журн. Сиб. федер. ун-та. Техники и технологии, 2022, 15(8). С. 975–985.
4. Васильченко А.М. Решение задач анализа данных на основе машинного обучения / Васильченко А.М. // Universum: технические науки. №9–1 (114). 2023. С. 50–54.
5. Ключев Р.В. Прогнозирование планового потребления электроэнергии для объединенной энергосистемы с помощью машинного обучения / Р.В. Ключев, А.Д. Моргоева, О.А. Гаврина, И.И. Босиков, И.Д. Моргоев // Записки горного института. 2023. №261. С. 392–402.
6. Конев К.А. Использование методов машинного обучения в задачах принятия решений при обеспечении качества в приборостроении / К.А. Конев // Экономика. Информатика. 2022. №4. С. 820–832.
7. Константинов А.А. Разработка методики оценки и прогнозирования уровня надежности энергетического оборудования ТЭС на базе показателей технического состояния / А.А. Константинов, М.М. Султанов // Вестник КГЭУ. 2021. №1. (49). С. 141–151.
8. Пискунова В.М. Анализ эффективности применения нелинейных моделей тепловых электростанций при исследовании надежности энергоснабжения потребителей / В.М. Пискунова, Д.С. Крупнев, // Информационные и математические технологии в науке и управлении. — 2023. — № 3 (31). С. 86–93.
9. Шишков Е.М. Прогнозирование временных рядов с применением методов машинного обучения на примере графика выдачи мощности электрической станции / Е.М. Шишков, А.В. Проничев, А.А. Савельев // Международный научно-исследовательский журнал. — 2022. — №2 (116). С. 56–60.
10. Хальясма А.И. Анализ ошибок применения алгоритмов машинного обучения в задачах электроэнергетики / А.И. Хальясма, П.В. Матренин, С.А. Ерошенко // Электроэнергия. Передача и распределение. 2021. №3 (66). С. 46–53.