

УДК 004.85

Автоматизация анализа профилограмм с использованием методов машинного обучения

Дудин Александр Вячеславович

Спасенов Алексей Юрьевич (научный руководитель)

МГТУ им. Н.Э. Баумана, Москва, Россия

Рассмотрена задача автоматизации анализа металлических поверхностей с использованием методов машинного обучения. Основная цель — классификация типов поверхностей и оценка их шероховатости. Работа включает математическую формализацию задачи классификации, обзор существующих методов оценки шероховатости металлов, описание процесса формирования обучающего набора данных, а также обучение и сравнение моделей классификации профилограмм, представленных в виде одномерных временных рядов.

Ключевые слова: автоматизация, контроль качества, машинное обучение, профилограмма, классификация одномерных временных рядов

Введение. Качество поверхности металла оказывает прямое влияние на надежность, износостойкость и функциональность деталей. Класс шероховатости определяет пригодность поверхности к тем или иным условиям эксплуатации. В качестве одного из подходов к автоматизированной оценке шероховатости рассматривается анализ профилограмм, представляющих собой временные ряды, содержащие информацию о микрогеометрии поверхности, формируемой различными технологическими процессами. Такой подход позволяет учитывать характерные особенности сигнала без необходимости ручного определения измерительных характеристик.

Обзор существующих подходов. При оценке шероховатости поверхности одним из распространенных показателей являются параметры Ra и Rz [1]. Однако в случаях, когда на измеряемом профиле присутствует волнистость, значения этих параметров отражают не только микрорельеф (шероховатость), но и глобальные характеристики поверхности. Таким образом, без применения фильтрации, разделяющей шероховатость и волнистость, величины Ra и Rz могут быть завышены и не отражать истинную шероховатость поверхности. Это, в свою очередь, может привести к ошибочной оценке класса поверхности. Для учета неявных признаков, характеризующих поверхность, и повышения точности оценки ее класса было принято решение использовать методы машинного обучения. С этой целью были отобраны несколько подходов к решению поставленной задачи, в рамках которых проведено тестирование наиболее эффективных моделей, доступных на текущий момент.

В работе рассматриваются три подхода, применимых для классификации профилограмм как одномерных временных рядов: признаковое представление, шейплет-преобразование и символьное представление.

В рамках признакового подхода используется модель TSFreshClassifier [2], основанная на автоматическом извлечении признаков временных рядов с помощью библиотеки TSFresh. Этот метод формирует обширный набор характеристик, включая ряд статистических (среднее, дисперсия, асимметрия, эксцесс), частотных (энергия спектра, амплитудные характеристики), автокорреляционных и трендовых признаков. На основе полученных характеристик обучается выбранный оценщик, чаще всего — случайный лес.

Для подхода, основанного на шейплет-преобразовании [3], применяется модель ShapeletTransformClassifier [4]. Шейплет представляет собой краткую подпоследовательность временного ряда, обладающую информативностью для классификации. Временной ряд преобразуется с помощью RandomShapeletTransform [5], который случайным образом выбирает множество шейплетов и вычисляет минимальное расстояние между каждым шейплетом и временным рядом. После этого значение признака определяется по пороговому правилу: если расстояние меньше порога — значение признака равно 1, иначе — 0. Таким образом, каждый шейплет формирует бинарный признак. Полученное представление подается на вход ансамблевого классификатора RotationForest [6].

В рамках символьного подхода используется модель TemporalDictionary-Ensemble (TDE) [7], основанная на базовом классификаторе IndividualTDE [8], который, в свою очередь, базируется на символьном представлении временных рядов посредством SFA (Symbolic Fourier Approximation) [9]. Данный метод описывается следующим образом. Каждый временной ряд разбивается на перекрывающиеся окна фиксированной длины, для которых выполняется дискретное преобразование Фурье с сохранением некоторого количества комплексных коэффициентов. Далее коэффициенты дискретизируются с использованием методов биннинга и заданного размера алфавита, что позволяет каждому окну преобразоваться в «слово» фиксированной длины. Формируется гистограмма распределения полученных слов с учетом концепции пространственной пирамиды. Пространственная пирамида — это способ разбиения временного ряда на несколько сегментов, для каждого из которых независимо применяется SFA для получения гистограмм, что позволяет учитывать локальные особенности временного ряда. Дополнительной особенностью данной модели является автоматическая оптимизация гиперпараметров. Сначала случайным образом выбираются стартовые комбинации, затем с помощью модели гауссовского процесса и LOOCV определяется оптимальное направление дальнейшего поиска, а в финальный ансамбль включаются лучшие модели с учетом заданного ограничения по их количеству.

Математическая постановка задачи классификации. Задача классификации формулируется следующим образом. Пусть $X = \{x_1, x_2, \dots, x_n\}$ — множество объектов, где n — количество объектов в выборке. Также дано $Y = \{1, \dots, K\}$ — множество классов, где K — количество классов. Цель заключается в определении для каждого x_i класса y_i , принадлежащего одному из K заранее заданных классов.

Математически задача сводится к построению алгоритма (классификатора), который отображает каждый объект x_i в один из классов Y .

Для построения алгоритма используется параметрическое семейство алгоритмов $A = \{a(x, \theta) | \theta \in \Theta\}$, где $a(x, \theta): X \rightarrow Y$ — алгоритм с параметрами θ , которые определяют его поведение; Θ — пространство параметров.

Метод обучения классификатора μ строит алгоритм $a = \mu(X^l)$, используя обучающую выборку $X^l = \{(x_1, y_1), (x_2, y_2), \dots, (x_\ell, y_\ell)\}$.

Процесс обучения задается отображением

$$\mu: X^l \rightarrow a,$$

где μ строит алгоритм a , который затем используется для решения задачи классификации.

Математическая постановка задачи оптимизации. Обучение моделей машинного обучения направлено на повышение качества их работы на заданной обучающей выборке либо, эквивалентно на минимизацию ошибки. Такая ошибка формализуется с помощью эмпирического риска — функционала качества алгоритма a на обучающем наборе данных Y^l :

$$Q(a, Y^l) = \frac{1}{l} \sum_{i=1}^l L(a(x_i), c_i),$$

где $L(a(x), c)$ — функция потерь, которая отражает величину ошибки алгоритма $a \in A$ на объекте $x \in X$ с истинной меткой c .

В задачах классификации в качестве функции потерь часто применяется кросс-энтропия

$$CE = -\sum_{i=1}^K c_i \log \hat{c}_i,$$

где c_i — метка класса (1, если объект x принадлежит классу c_i , и 0 в противном случае); $\hat{c}_i$ — предсказание алгоритма классификации.

Таким образом, задача обучения сводится к нахождению параметров модели, минимизирующих эмпирический риск

$$a = \mu(Y^l, \theta) = \operatorname{argmin}_{\theta \in \Theta} \sum_{i=1}^l CE_i.$$

Описание экспериментальных данных. Данные были получены с использованием контактного профилометра Mitutoyo SJ-210. Каждое измерение представляет собой одномерный временной ряд, отражающий профиль поверхности детали.

В работе использованы образцы четырех классов шероховатости (4, 5, 6 и 7 классы), соответствующие различным режимам точения. Для каждого класса собрано по 138 профилограмм, итого — 552 временных ряда, по 200 значений в каждом.

Пример поверхности четвертого класса шероховатости, с которой собиралась профилограмма, представлена на рис. 2.



Рис. 1. Профилометр Mitutoyo SJ-210




Рис. 2. Пример поверхности металла

Пример поверхности седьмого класса шероховатости, с которой собиралась профилограмма, представлен на рис. 3.

Соответствующая поверхностям на рис. 2 профилограмма, иллюстрирующая, как видимая структура поверхности отражается в форме временного ряда представлена на рис. 4. Соответствующая поверхностям на рис. 3 профилограмма, иллюстрирующая, как видимая структура поверхности отражается в форме временного ряда представлена на рис. 5.



Рис. 3. Пример поверхности металла

Данные были разделены на тренировочную, валидационную и тестовую выборки в пропорции 60:20:20. Такое соотношение обеспечивает баланс между объемом информации, доступной для построения модели, и надежностью оценки ее обобщающей способности. Тренировочная выборка используется для непосредственного обучения модели, валидационная — для подбора гиперпараметров и ранней остановки, предотвращающей переобучение, а тестовая — для финальной оценки качества модели на независимых данных, не использовавшихся в процессе обучения.




Рис. 4. Пример профилограммы поверхности металла




Рис. 5. Пример профилограммы поверхности металла

Обучение моделей классификации одномерных временных рядов на полученных наборах данных. В ходе эксперимента были получены величины метрик (см. таблицу).

Результаты классификации показывают, что модель ShapeletTransformClassifier продемонстрировала наилучшую точность (0,986) среди одномерных моделей, что может быть связано с ее способностью выявлять характерные локальные паттерны в профилограммах, которые являются временными рядами с повторяющимися структурными особенностями. TemporalDictionaryEnsemble (0,916) также показала высокую точность благодаря использованию словарного представления временных рядов, что позволяет эффективно кодировать повторяющиеся сегменты профилограммы. В то же время TSFreshClassifier (0,792) уступил другим одномерным моделям, так как, вероятно, при агрегации статистических признаков теряется информация о локальной структуре сигнала.

Полученные величины метрик

Модель	Тип данных	Точность модели
ShapeletTransformClassifier	Одномерные	0,986
TSFreshClassifier	Одномерные	0,792
TemporalDictionaryEnsemble	Одномерные	0,916
MobileNetV3Small	Двумерные	0,952

Закключение. Полученные результаты подтверждают, что высокоточная классификация профилограмм возможна без ручной перенастройки профилометра под каждую деталь. Это позволяет проводить измерения в едином режиме и автоматически определять класс поверхности, снижая влияние че-

ловеческого фактора и сокращая время контроля. Такой подход открывает путь к полной автоматизации этапа оценки шероховатости и интеграции моделей в системы производственного контроля качества.

Литература

- [1] ГОСТ 2789–73. *Шероховатость поверхности. Параметры и характеристики*. Москва, Изд-во стандартов, 1973, 7 с.
- [2] Time Series Machine Learning. URL: https://www.sktime.net/en/latest/api_reference/auto_generated/sktime.classification.feature_based.TSFreshClassifier.html (accessed 10.12.2024).
- [3] Guo K., Lim W.-Q., Labate D., Weiss G., Wilson E. Sparse multidimensional representation using shearlets. *Proceedings of SPIE*, 2006, vol. 5914, art. no. 59140u.
- [4] Time Series Machine Learning. URL: https://www.sktime.net/en/stable/api_reference/auto_generated/sktime.classification.shapelet_based.ShapeletTransformClassifier.html (accessed 15.12.2024).
- [5] Time Series Machine Learning. URL: https://www.sktime.net/en/stable/api_reference/auto_generated/sktime.transformations.panel.shapelet_transform.RandomShapeletTransform.html (accessed 15.12.2024).
- [6] Time Series Machine Learning. URL: https://www.sktime.net/en/stable/api_reference/auto_generated/sktime.classification.sklearn.RotationForest.html (accessed 16.12.2024).
- [7] Time Series Machine Learning. URL: https://www.sktime.net/en/latest/api_reference/auto_generated/sktime.classification.dictionary_based.TemporalDictionaryEnsemble.html (accessed 23.12.2024).
- [8] Series Machine Learning. URL: https://www.sktime.net/en/stable/api_reference/auto_generated/sktime.classification.dictionary_based.IndividualTDE.html (accessed 23.12.2024).
- [9] Schäfer P., Höggqvist M. SFA: a symbolic Fourier approximation and index for similarity search in high dimensional datasets. *Proc. of the 15th Int. Conf. on Extending Database Technology*, 2012. URL: <https://openproceedings.org/2012/conf/edbt/SchaferH12.pdf> (accessed 23.12.2024).

Automation of profilogram analysis using machine learning methods

Dudin Alexander Vyacheslavovich

Spasenov Aleksey Yurievich (*scientific advisor*)

BMSTU, Moscow, Russia

This study addresses the problem of automating the analysis of metallic surfaces using machine learning methods. The primary objective is to classify surface types and evaluate their roughness. The work includes a mathematical formulation of the classification task, a review of existing methods for assessing metal surface roughness, a description of the training dataset construction process, and the training and comparison of classification models based on profile measurements represented as one-dimensional time series.

Keywords: automation, quality control, machine learning, profilogram, one-dimensional time series classification