

Разработка SVM модели для предиктивного обслуживания металлорежущего оборудования

Н.Г. Джавадов, А.М. Амиров, В.М. Исмаилов

Национальное Аэрокосмическое Агентство, г. Баку, Азербайджан

Аннотация. Данная статья посвящена созданию модели машинного обучения для оптимизации обслуживания режущего инструмента с применением метода опорных векторов (SVM). В статье рассмотрены основные этапы создания модели многоклассовой классификации от предварительной обработки сырых сигналов до подбора гиперпараметров. Выбор алгоритма обусловлен вычислительной эффективностью, а также возможностью работы с данными с нелинейной структурой. В результате тестирования модели средняя точность достигла 81%. Полученные результаты демонстрируют, что алгоритм на основе метода опорных векторов может справиться с поставленной задачей в условиях ограниченных вычислительных мощностей.

Ключевые слова: машинное обучение, умное производство, метод опорных векторов, металлообработка, предиктивное обслуживание.

DOI: 10.14357/20790279250209 **EDN:** AMBERY

Введение

Металлообработка является сложным процессом, который сопровождается выработкой большого количества данных. Методы машинного обучения широко используются для анализа и выявления закономерностей в этих данных. Использование машинного обучения в производстве способно снизить время простоя оборудования, повысить производительность предприятия и улучшить качество выпускаемой продукции [1].

Одним из вариантов применения машинного обучения в производстве является мониторинг состояния оборудования. Неожиданные поломки вызывают простои технологического оборудования, что приводит к убыткам. Согласно последним исследованиям [2-4], незапланированные простои, вызванные неоптимальной стратегией обслуживания, могут снизить производительность предприятия до 20-35% в год.

Решением проблемы выхода из строя оборудования является их обслуживание, которое можно разделить на следующие виды:

1. Обслуживание при факте неполадки в оборудовании;
2. Плановое обслуживание;
3. Предиктивное обслуживание.

Наиболее простым является первый метод – обслуживание оборудования не проводится, пока

не произойдет неполадка. В этом случае время работы компонента может быть увеличено, но незапланированные застои неизбежны. Кроме незапланированных застоев, есть опасность возникновения сопутствующих неполадок, например, при поломке режущего инструмента в процессе резания есть риск повреждения заготовки или элементов станка.

Плановое обслуживание является более распространенной и заключается в обслуживании оборудования через определенное количество времени для предотвращения неожиданных поломок [5]. Это предполагает, что текущее состояние оборудования не учитывается, что приводит к нерациональным затратам, т.к. потенциал оборудования с точки зрения времени полезной работы не раскрывается в полной мере. Кроме того, плановое обслуживание не учитывает динамику изменения нагрузки на оборудование. Соответственно, инженеру по обслуживанию на производстве приходится искать компромисс между этими двумя методами. Предиктивное обслуживание является же новым подходом, позволяющим объединить преимущества двух вышеописанных методов. Этот метод основан на мониторинге компонентов станка в реальном времени. Концепция предиктивного обслуживания заключается в принятии мер на ранних этапах, когда элементы станка демонстрируют

определенное поведение, которое может приводить к отказу оборудования, ухудшению производительности или снижению качества продукции. Соответственно, ранняя реакция на нетипичное поведение переменных технологического процесса позволяет предотвращать незапланированные простои, понижения качества и производительности [6].

Одним из самых нагруженных и работающих в экстремальных условиях элементов является режущий инструмент. В процессе фрезерования вращающийся режущий инструмент снимает материал с обрабатываемой заготовки для получения требуемой формы. В результате взаимодействия режущего инструмента, поверхности заготовки и стружки происходит изменение формы режущих кромок инструмента. Это явление, известное также как износ, оказывает значительное влияние на качество обрабатываемой поверхности деталей [7]. Для обеспечения качества производимой продукции необходимо отслеживать и контролировать износ режущего инструмента.

На рис. 1 приводится типичная кривая износа режущего инструмента. Кривую можно разделить, относительно времени работы, на 3 этапа. На 1 этапе происходит интенсивный износ с переходом в устойчивый режим. На последнем этапе степень износа ускоряется, приводя в конечном итоге к выходу инструмента из строя. Соответственно, износ режущего инструмента – это нелинейный процесс, срок службы которого не является постоянной даже при одинаковых условиях эксплуатации, что усложняет процесс его мониторинга. Задачей предиктивного обслуживания в данном случае является определение начала катастрофического износа режущего инструмента, для того чтобы своевременно спланировать его замену. С этой целью, в рамках данной статьи, рассматривается разработка алгоритма на основе метода опорных векторов для предиктивного обслуживания режущего инструмента.




Рис. 1. График зависимости износа инструмента от времени резания

1. Методология и материалы

Описание модели. Метод опорных векторов – это метод контролируемого машинного обучения, который используется для задач классификации и регрессии. Целью метода опорных векторов в задачах классификации является максимизация расстояний от разделяющей гиперплоскости до ближайших объектов, которые называются опорными векторами [8]. На рис. 2 изображен подход метода опорных векторов для бинарной классификации линейно разделимых объектов.




Рис. 2. Геометрическая интерпретация метода опорных векторов для бинарной классификации для линейно разделимого случая, где x_1 и x_2 – признаки объектов, круги и квадраты – объекты

Выбор модели SVM обуславливается несколькими причинами. SVM обладает существенным достоинством, заключающимся в эффективной работе с ограниченными объемами данных, что типично для задач в промышленности ввиду сложности и дороговизны сбора данных. Это достоинство вытекает из принципа работы алгоритма – для построения разделяющей гиперплоскости используются не все объекты, а только лишь находящиеся ближе всего к границам классов, называемые опорными векторами. Это преимущество выделяет SVM на фоне таких алгоритмов как ансамблевые модели или глубокие нейронные сети. Кроме того, описанный алгоритм построения, а также механизмы регуляризации позволяют снизить чувствительность модели к шумам и выбросам. Также необходимо отметить универсальность алгоритма SVM перед такими методами авторегрессионного анализа временных рядов как ARMA, ARIMA и SARIMA, которые предполагают стационарную природу временных рядов, либо требуют преобразования нестационарных временных рядов в стационарные. Упомянутые методы, как правило, используются для задач регрессии, в то время как




Рис. 3. Временные ряды сигналов для первого прохода, где smcAC – переменный ток двигателя шпинделя, smcDC – постоянный ток двигателя шпинделя, vib_table – вибрация стола, vib_spindle – вибрация шпинделя, AE_table – акустическая эмиссия на столе, AE_spindle – акустическая эмиссия на шпинделе

SVM может применяться, как к задачам регрессии, так и классификации. Кроме того, упомянутые методы авторегрессионного анализа чувствительны к шумам и выбросам.

Еще одним достоинством SVM модели является способность работать с нелинейными зависимостями. Для классификации линейно неразделимых объектов, согласно статистической теории обучения Вапника-Червоненкиса [9], возможно преобразование исходного пространства в пространство более высокой размерности, в котором объекты можно будет линейно разделить.

Для преобразования пространства используются ядровые функции, в данном исследовании тестировались линейная, полиномиальная и радиально-базисные функции.

С учетом всего вышесказанного, можно сделать вывод, что выбор алгоритма SVM является целесообразным для решения задач предиктивного обслуживания оборудования в промышленности.

Описание данных. Для обучения модели использовался открытый набор данных с обрабатывающим центром японского производства Matsuura MC-510V [10]. В ходе сбора данных фрезеровалась заготовка размерами 483 мм × 178 мм × 51 мм с

различными параметрами резания. После каждого прохода замерялся износ задней поверхности инструмента. В процессе сбора данных регистрировались 6 сигналов с частотой дискретизации 250 Гц. На рис. 3 приведена визуализация временных рядов для одного прохода, выполненная на языке программирования Python и библиотеки Matplotlib. Используемый в данной статье набор данных состоит из 167 записей, каждый из них представляет один проход, в одном проходе для каждого сигнала собрано по 9000 значений.

Описание процесса разработки модели. Схематическая диаграмма создания классификатора на базе методе опорных векторов показана на рис. 4. На первом этапе производилась предварительная обработка сигналов. Из набора данных удалялись аномальные временные ряды, например, в одном из проходов датчик вибраций на столе станка не регистрировал сигналы. Далее заполнялись пропуски в целевой переменной, для простоты реализации был выбран метод линейной интерполяции. Также при предварительной обработке из временных рядов сигналов были удалены зоны входы и выхода инструмента в заготовку. В конце предварительной обработки все временные ряды




Рис. 4. Схема создания классификатора для предиктивного обслуживания режущего инструмента

были размечены в 3 класса в зависимости от степени износа: до 0.2 мм – нормальный износ, 0.2-0.4 мм – предупреждающий износ, от 0.4 мм – критический износ.

На втором этапе каждый временной ряд был разделен на окна размером 50 элементов и со сдвигом в 50 без повторяющихся записей в окнах. Перед обучением модели проводилось извлечение признаков для выделения полезной информации из временных рядов. Кроме того, для обучения модели на базе метода опорных векторов, каждый признак объекта должен быть представлен в виде одного числа в векторе признаков. Соответственно, далее из каждого окна были выделены статистические признаки, описанные в табл. 1.

При переходе от временных рядов к числовым признакам на заданном интервале, извлеченные признаки обобщают поведение временного ряда. Данная методология позволяет повысить устойчивость модели к шумовым значениям. Однако, потеря временной структуры в данных в процессе обучения может привести к низкой точности модели.

Для сохранения временной структуры в данном исследовании была использована временная

перекрестная проверка (time series cross-validation) в процессе обучения и оценки модели. Данный метод не перемешивает данные, модель обучается на прошлых данных и тестируется на будущих, соответственно, обеспечивается корректная имитация реальных условий работы модели.

Кроме того, сохранение временной зависимости возможно извлечением новых признаков, учитывающих временную структуру, а также использованием более продвинутых методов для преобразования временного ряда в другое представление. Однако, в рамках данного исследования, извлечение признаков ограничилось было ограничено 7 вышеуказанными признаками для простоты реализации кода.

На третьем этапе был применен метод главных компонент (МГК) для снижения размерности признакового пространства. После второго этапа из 6 признаков (6 временных рядов для каждого прохода) было получено 42 признака для каждого объекта. Всего после разделения на окна и выделение признаков в обучающей выборке получилось 1600 объектов.

Как известно [1], высокая размерность данных может привести к проблеме, известной как «проклятие размерности», которая приводит к увеличению трудоемкости обучения, а также к увеличению склонности модели к переобучению. Переобучение модели – это явление, когда на обучающей выборке модель показывает высокие результаты точности, а на тестовой (данные которые не участвовали в обучении) низкие. Кроме того, применение МГК может повысить точность модели, если набор данных содержит большое количество нерелевантных признаков или шумов.

На последнем этапе происходило обучение модели на различных гиперпараметрах. Для обучения и тестирования модели были выбраны разные проходы, но с одинаковыми режимами резания и материалом. Модель обучалась локально на ПК со следующими характеристиками:

Процессор – Ryzen 7 4800H.

Видеокарта – Nvidia Geforce GTX 1650Ti.

Объем оперативной памяти – 16 Гб.

Объем видеопамати – 4 Гб.

Операционная система – Windows 11.

Табл. 1

Признаки, выделенные из каждого окна временных рядов

№	Название признака	Определение
1	Межквартильный размах	$T_{IQR} = Q_3 - Q_1$
2	Среднее абсолютное отклонение	$T_{MAD} = \frac{1}{n} \sum_{i=1}^n x_i - \bar{x} $
3	Дисперсия	$T_{var} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$
4	Стандартное отклонение	$T_{sd} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
5	Среднеквадратичное значение	$T_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$
6	Коэффициент эксцесса	$T_{ku} = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)T_{sd}^4}$
7	Коэффициент асимметрии	$T_{sk} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)T_{sd}^3}$

2. Обсуждение

В рамках проведенного исследования была обучена модель многоклассовой классификации на основе метода опорных векторов для определения степени износа режущего инструмента. Обучение было проведено на предварительно обработанных данных. Для избежания переобучения, обучение и тестирование модели происходили на различных выборках данных.

Для оценки эффективности модели была выбрана метрика точности (ассигасу), которая выражается в виде отношения количества правильно классифицированных классов ко всем предсказаниям модели. Для бинарной классификации метрика вычисляется следующим образом:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

где TP (True Positive) – количество правильно классифицированных положительных классов, TN (True Negative) – количество правильно классифицированных негативных классов, FP (False Positive) – количество неправильно классифицированных отрицательных классов, FN (False Negative).

Данная метрика широко применяется также в задачах многоклассовой классификации, в которой, как и для задач бинарной классификации, вычисляется доля правильных ответов от всего количества ответов классификатора.

При обучении модели без уменьшения размерности пространства на изначальных 42 признаках происходило явное переобучение модели. Наилучшие результаты были получены с применением полиномиальной ядерной функции, по этой причине в последующих экспериментах использовалась только эта ядерная функция.

В табл. 2 приведены результаты экспериментов зависимости точности классификатора от количества главных компонент. Проанализировав данную таблицу можно сделать вывод, что при высокой размерности признакового пространства

происходит переобучение. С уменьшением количества компонент точность на тестовой выборке растет и достигает наилучшего результата при двух главных компонентах. Соответственно, можно сделать вывод о сильной избыточности и коррелированности изначального признакового пространства.

Для модели с полиномиальным ядром и двумя главными компонентами была построена матрица ошибок (рис 5.). Данная модель обеспечила точность классификатора в 81%. Проанализировав матрицу ошибок можно сделать вывод, что модель уверенно классифицирует класс «Предупреждение» с точностью 95.5%, для класса «Критично» точность достигается в 87.7%. Наибольшее количество ошибок приходится на ошибку классификатора между классами «Норма» и «Предупреждение», что может быть вызвано схожестью извлеченных признаков на начальном этапе износа режущего инструмента. Однако, стоит отметить, что ни один объект из класса «Норма» не был классифицирован как «Критично», что может быть важно в условиях реального производства т.к. модель демонстрирует устойчивость к ложным тревогам.




Рис. 5. Матрица ошибок классификатора

Зависимость точности классификатора на тестовой и тренировочной выборке от количества главных компонент

Табл. 2

Размерность пространства (количество признаков)	Точность классификатора на тестовой выборке	Точность классификатора на тренировочной выборке
42	0.56	1
40	0.56	1
20	0.52	1
10	0.49	0.98
5	0.75	0.93
2	0.81	0.89
1	0.76	0.85

Заключение

1. Разработана модель классификации степени износа режущего инструмента для предиктивного обслуживания металлорежущих станков на основе метода опорных векторов.
2. Полученные результаты демонстрируют, что без продвинутых алгоритмов глубинного обучения, а также без облачных вычислений возможно решение поставленной задачи с применением локальных вычислительных систем. Это снижает затраты на реализацию системы и делает её доступной для производства.
3. В данной работе извлечение признаков происходило во временном диапазоне. Для повышения точности и улучшения обобщающей способности модели также можно использовать более продвинутые методы, в том числе и в частотных и частотно-временных диапазонах.
4. Необходимо также отметить, что в отличие от алгоритмов глубинного обучения, эффективность работы моделей на основе классических алгоритмов машинного обучения и в частности метода опорных векторов, в значительной степени зависит от качества и информативности извлеченных признаков из сырых данных. Данная проблема может считаться неактуальной для алгоритмов глубинного обучения, т.к. они способны автоматически извлекать признаки из данных.

Литература

1. Джавадов Н.Г., Амиров А.М., Исмаилов В.М. Технические аспекты создания системы мониторинга металлорежущего оборудования с применением машинного обучения // Вестник компьютерных и информационных технологий. 2024. Т. 21, № 10. С. 10–16. DOI: 10.14489/vkit.2024.10.pp.010-016.
2. Montero Jimenez J.J., Schwartz S., Vingerhoeds R., et al. Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics // Journal of Manufacturing Systems. 2020. Vol. 56. P. 539–557. DOI: 10.1016/j.jmsy.2020.04.012.
3. Fahle S., Prinz C., Kühlenkötter B. Systematic review on machine learning (ML) methods for manufacturing processes – Identifying artificial intelligence (AI) methods for field application // Procedia CIRP. 2020. Vol. 93. P. 413–418. DOI: 10.1016/j.procir.2020.04.109.
4. Montero Jimenez J.J., Schwartz S., Vingerhoeds R., Grabot B., Salaiin M. Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics // Journal of Manufacturing Systems. 2020. Vol. 56. P. 539–557. DOI: 10.1016/j.jmsy.2020.04.012.
5. Çınar Z.M., Nuhu A.A., Zeeshan Q., Korhan O., Asmael M., Safaei B. Machine learning in predictive maintenance towards sustainable smart manufacturing in Industry 4.0 // Sustainability. 2020. Vol. 12, No. 19. P. 8211. DOI: 10.3390/su12198211.
6. Krupitzer C., Wagenhals T., Züfle M., Lesch V., Schäfer D., Mozaffarin A., Edinger J., Becker C., Kounev S. A survey on predictive maintenance for Industry 4.0 // arXiv preprint. 2020. arXiv:2002.08224. DOI: 10.48550/arXiv.2002.08224. URL: <https://doi.org/10.48550/arXiv.2002.08224>
7. Munaro R., Attanasio A., Del Prete A. Tool wear monitoring with artificial intelligence methods: A review // Journal of Manufacturing and Materials Processing. 2023. Vol. 7, No. 4. P. 129. DOI: 10.3390/jmmp7040129.
8. James G., Witten D., Hastie T., Tibshirani R. An Introduction to Statistical Learning, With Applications in Python. 2nd ed. New York: Springer, 2023. 597 p.
9. Vapnik V.N. The Nature of Statistical Learning Theory. New York: Springer, 2000. 314 p.
10. Agogino A., Goebel K. Milling Data Set [Электронный ресурс]. 2007. Режим доступа: <http://ti.arc.nasa.gov/project/prognostic-data-repository> (дата обращения: [2025]).

Джавадов Натиг Гаджи. Национальное Аэрокосмическое Агентство, г. Баку, Азербайджан. Генеральный Директор, доктор технических наук, профессор. Область научных интересов: информационные технологии, автоматизация производства. E-mail: cavadov-natiq@mail.ru

Амиров Али Мансималы. Национальное Аэрокосмическое Агентство, г. Баку, Азербайджан. Главный научный сотрудник, кандидат технических наук, доцент. Область научных интересов: информационные технологии, автоматизация производства. E-mail: ali.amirov@mail.com

Исмаилов Вугар Мехман. Национальное Аэрокосмическое Агентство, г. Баку, Азербайджан. Научный сотрудник, докторант. Область научных интересов: информационные технологии, автоматизация производства. E-mail: ismailovvugar99@gmail.com (ответственный за переписку)

Development of an SVM model for predictive maintenance of metal-cutting equipment.

N.G. Javadov, A.M. Amirov, V.M. Ismayilov

National Aerospace Agency, Baku, Azerbaijan

Abstract. This article is devoted to the development of a machine learning model for optimizing cutting tool maintenance using the support vector machines (SVM). The paper considers the main stages of creating a multiclass classification model from pre-processing of raw signals to selection of hyperparameters. The choice of the algorithm is determined by computational efficiency, as well as the possibility of working with data with nonlinear structure. As a result of testing the model, the average accuracy reached 81%. The obtained results demonstrate that the algorithm based on the method of support vectors can handle the task in conditions of limited computational power.

Keywords: *machine learning, smart manufacturing, support vector method, metalworking, predictive maintenance.*

DOI: 10.14357/20790279250209 **EDN:** AMBERY

References

1. Javadov N.G., Amirov A.M., Ismayilov V.M. 2024. Tehnicheskie aspekty sozdaniya sistemy monitoringa metallorazhushhego oborudovaniya s primeneniem mashinnogo obuchenija. Vestnik komp'yuternykh i informacionnykh tehnologiy 21(10):10–16. doi:10.14489/vkit.2024.10.pp.010-016.
2. Montero Jimenez J.J., Schwartz S., Vingerhoeds R., et al. Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics // Journal of Manufacturing Systems. 2020. Vol. 56. P. 539–557. DOI: 10.1016/j.jmsy.2020.04.012.
3. Fahle S., Prinz C., Kuhlentötter B. Systematic review on machine learning (ML) methods for manufacturing processes – Identifying artificial intelligence (AI) methods for field application // Procedia CIRP. 2020. Vol. 93. P. 413–418. DOI: 10.1016/j.procir.2020.04.109.
4. Montero Jimenez J.J., Schwartz S., Vingerhoeds R., Grabot B., Salaiin M. Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics // Journal of Manufacturing Systems. 2020. Vol. 56. P. 539–557. DOI: 10.1016/j.jmsy.2020.04.012.
5. Çınar Z.M., Nuhu A.A., Zeeshan Q., Korhan O., Asmael M., Safaei B. Machine learning in predictive maintenance towards sustainable smart manufacturing in Industry 4.0 // Sustainability. 2020. Vol. 12, No. 19. P. 8211. DOI: 10.3390/su12198211.
6. Krupitzer C., Wagenhals T., Züfle M., Lesch V., Schäfer D., Mozaffarin A., Edinger J., Becker C., Kounev S. A survey on predictive maintenance for Industry 4.0 // arXiv preprint. 2020. arXiv:2002.08224. DOI: 10.48550/arXiv.2002.08224. URL: <https://doi.org/10.48550/arXiv.2002.08224>
7. Munaro R., Attanasio A., Del Prete A. Tool wear monitoring with artificial intelligence methods: A review // Journal of Manufacturing and Materials Processing. 2023. Vol. 7, No. 4. P. 129. DOI: 10.3390/jmmp7040129.
8. James G., Witten D., Hastie T., Tibshirani R. An Introduction to Statistical Learning, With Applications in Python. 2nd ed. New York: Springer, 2023. 597 p.
9. Vapnik V.N. The Nature of Statistical Learning Theory. New York: Springer, 2000. 314 p.
10. Agogino A, Goebel K. Milling Data Set. 2007. doi:<http://ti.arc.nasa.gov/project/prognostic-data-repository>.

Natig H. Javadov. Professor. Doctor of Technical Sciences, National Aerospace Agency, Baku, Azerbaijan. Research interests: information technologies, production automation. E-mail: cavadov-natig@mail.ru

Ali M. Amirov. Candidate of Technical Sciences. National Aerospace Agency, Baku, Azerbaijan. Research interests: information technologies, production automation. E-mail: ali.amirov@mail.com

Vugar M. Ismayilov. National Aerospace Agency, Baku, Azerbaijan. Research interests: information technologies, production automation. E-mail: ismailovvugar99@gmail.com