



Обработка металлов (технология • оборудование • инструменты)

Сайт журнала: http://journals.nstu.ru/obrabotka_metallov



Прогнозирование интенсивности изнашивания твёрдых PVD-покрытий с использованием гибридной модели Taguchi-RSM-ML с интерпретируемостью на основе SHAP-анализа

Умеш Субхаш Патхаркар^{1, а}, Сунил Анпарао Патил^{1, б}, Нитин Амбхоре^{2, с, *}

¹ Государственный инженерный колледж, Чх. Самбхаджинагар, 431005, Махараштра, Индия

² Технологический институт Вишвакарма, Пунский университет имени Савитрибаи Пхуле, Пуна, 411037, Махараштра, Индия

^а <https://orcid.org/0009-0005-9303-641X>, patharkarumeshsubhash@gmail.com; ^б <https://orcid.org/0009-0000-4804-0720>, sakpatil967@gmail.com;

^с <https://orcid.org/0000-0001-8468-8057>, nitin.ambhore@vit.edu

ИНФОРМАЦИЯ О СТАТЬЕ

УДК 621.793.18:621.891:004.85

История статьи:

Поступила: 06 апреля 2026

Рецензирование: 11 апреля 2026

Принята к печати: 30 апреля 2026

Доступно онлайн: 15 июня 2026

Ключевые слова:

PVD-покрытия

Износ

Методология поверхности отклика

Случайный лес

Градиентный бустинг

SHAP-анализ

АННОТАЦИЯ

Введение. Поведение твердых покрытий, нанесенных методом физического осаждения из паровой фазы (PVD), трудно прогнозировать из-за нелинейной взаимосвязи между химическим составом покрытия, толщиной осажденного слоя, рабочей температурой и приложенной контактной нагрузкой. Многомерное картирование параметров с помощью исчерпывающих экспериментов требует значительных временных и финансовых затрат. **Цель работы:** реализовать гибридную архитектуру, работающую с небольшими объемами данных, которая объединяет планирование Taguchi, метод анализа поверхности отклика (RSM) и машинное обучение (ML) для прогнозирования и оптимизации износостойкости на основе небольшого набора данных ($n = 28$). **Методы.** Три типа покрытий – AlTiN, CrN и TiC – были испытаны в диапазоне температур 40...50 °C, диапазоне контактных нагрузок 5...15 Н и диапазоне толщины покрытия 2...4 мкм. Был проведен дисперсионный анализ (ANOVA) для выявления параметра, оказывающего наиболее сильное влияние на износ. С использованием метода анализа поверхности отклика разработана прогностическая модель износа. **Результаты и обсуждение.** Дисперсионный анализ показал, что нагрузка и химический состав покрытия являются факторами, оказывающими наиболее сильное влияние на износ. В исследованном диапазоне температура и толщина не были признаны значимыми факторами. RSM-модель оказалась статистически значимой для прогнозирования контактной нагрузки и химического состава покрытия с $R^2 = 0,901$ (скорректированный $R^2 = 0,834$, RMSE = 0,0076). Среди протестированных моделей машинного обучения с использованием пятикратной перекрестной проверки алгоритм случайного леса (RF) показал наивысшую обобщающую способность ($CV R^2 = 0,755$), а градиентный бустинг (GB) – наилучшее общее соответствие ($R^2 = 0,913$). SHAP-анализ показал, что основной вклад вносит химический состав покрытия, затем контактная нагрузка, а вклад температуры незначителен. Оптимизация с помощью градиентного бустинга показала, что AlTiN-покрытие с толщиной 4 мкм под контактной нагрузкой 15 Н и при температуре 50 °C проявляет себя наилучшим образом, при этом ожидаемая интенсивность износа составляет 0,010823 мм³/(Н·м). Предложенная структура демонстрирует достоверное и интерпретируемое прогнозирование износа с использованием ограниченных экспериментальных данных.

Для цитирования: Патхаркар У., Патил С., Амбхоре Н. Прогнозирование интенсивности изнашивания твёрдых PVD-покрытий с использованием гибридной модели Taguchi-RSM-ML с интерпретируемостью на основе SHAP-анализа // Обработка металлов (технология, оборудование, инструменты). – 2026. – Т. 28, № 2. – С. 318–334. – DOI: 10.17212/1994-6309-2026-28.2-318-334.

Введение

Физическое осаждение из паровой фазы (PVD) стало широко используемым методом нанесения твердых покрытий, необходимых для повышения производительности и долго-

вечности режущих инструментов, штампов для формовки и прецизионных механических компонентов. PVD-покрытия полезны тем, что перераспределяют напряжения в контактной зоне, уменьшают адгезионный перенос и снижают интенсивность абразивного износа благодаря формированию тонкого износостойкого слоя на контактной границе, что значительно увеличивает срок службы компонентов [1, 2]. Среди различных типов покрытий нитрид титана и алюминия

*Адрес для переписки

Амбхоре Нитин, к.т.н., доцент

Технологический институт Вишвакарма,

411037, Пуна, Махараштра, Индия

Тел.: +91-2026950441, e-mail: nitin.ambhore@vit.edu

(AlTiN), нитрид хрома (CrN) и карбид титана (TiC) привлекли значительное внимание из-за своих уникальных механических и химических свойств.

Известно, что AlTiN-покрытия обладают высокой твердостью и отличной стойкостью к окислению, что обусловлено образованием стабильного оксидного трибослоя из оксида алюминия в процессе скольжения. Напротив, CrN-покрытия лучше с точки зрения коррозионной стойкости и снижения коэффициента трения, что делает их применимыми в агрессивных условиях, в то время как TiC-покрытие обеспечивает высокую твердость, но подвержено хрупкому разрушению при высоких нагрузках [3, 4]. Несмотря на эти сильные стороны, трибологическое поведение PVD-покрытий контролируется сложным взаимодействием технологических переменных (например, толщины покрытия, температуры и приложенной нагрузки), и возможность аналитического прогнозирования этих переменных ограничена [5].

Традиционные методы планирования эксперимента (DoE), такие как метод Taguchi и метод анализа поверхности отклика (RSM), широко используются для оптимизации трибологических параметров. Метод Taguchi позволяет эффективно отсеивать параметры с помощью ортогональных массивов, в то время как RSM позволяет осуществлять непрерывное моделирование и статистический анализ с помощью полиномиальной регрессии [6, 7]. Тем не менее эти методы принципиально ограничены в своей способности улавливать существенные нелинейности и взаимодействия высших порядков, которые существуют в процессах износа [8].

Для преодоления этих недостатков методы машинного обучения (ML) стали эффективными инструментами моделирования сложных трибологических систем. Такие ансамблевые методы, как алгоритм случайного леса и градиентный бустинг, продемонстрировали высокую прогностическую способность при анализе износа и эффективности покрытий, особенно в условиях ограниченного объема данных [9, 10]. Недавние исследования также показали полезность ML для прогнозирования поведения износа в системах покрытий и материалах, хотя большинство подходов не являются интерпретируемыми или совместимыми с физически обоснованными

моделями проектирования [11, 12]. Более того, системы объяснимого искусственного интеллекта (XAI), включая SHAP, позволили глубже понять вклад признаков, повышая прозрачность и надежность модели [13, 14].

Несмотря на эти разработки, по-прежнему отсутствует интегрированная структура, объединяющая статистическое планирование, нелинейное моделирование и интерпретируемое машинное обучение для систем PVD-покрытий. В доступной литературе, как правило, описаны либо отдельные методы DoE, либо отдельные модели ML, при этом не уделяется должного внимания методу наибольшей беспристрастности и эффективности использования данных.

Настоящая статья восполняет этот пробел путем создания трехуровневой гибридной модели, которая объединяет анализ Taguchi, RSM и ML для прогнозирования интенсивности износа PVD-покрытий. В работе поставлены следующие *цели*:

- статистически установить значимость типа покрытия, нагрузки, температуры и толщины на интенсивность износа PVD-покрытия с помощью анализа Taguchi-RSM;
- оценить прогностическую способность ансамблевых моделей машинного обучения в условиях ограниченного размера выборки ($n = 28$) для трибологического прогнозирования;
- выявить и количественно оценить нелинейные взаимодействия между входными факторами с помощью анализа важности признаков на основе SHAP;
- определить физически реалистичные оптимальные конфигурации покрытий, подтвержденные гибридным консенсусом между статистикой и машинным обучением.

Эта интегрированная структура предлагает эффективный с точки зрения использования данных и интерпретируемый подход к трибологическому моделированию.

Методы

Были исследованы твердые PVD-покрытия трех различных химических составов – нитрид алюминия и титана (AlTiN), нитрид хрома (CrN) и карбид титана (TiC), поскольку они обладают различными трибологическими и механическими свойствами [15–17]. Покрытия наносили

на подложки из закаленной инструментальной стали с использованием промышленной катодно-дуговой PVD-системы. Параметры осаждения были оптимизированы для каждого типа покрытия: AlTiN осаждался при давлении азота 3,5 Па, токе мишени 150 А, температуре подложки 450 °С и времени осаждения 90 мин; CrN – при давлении азота 3,0 Па, токе мишени 120 А, температуре подложки 400 °С и времени осаждения 80 мин; TiC – при давлении ацетилена/аргона 2,5 Па, токе мишени 130 А, температуре подложки 420 °С и времени осаждения 85 мин. Эти параметры были выбраны для обеспечения равномерного качества покрытия и адгезии.

Толщину покрытия контролировали и проверяли как методом шарикового истирания (ball-cratering), так и с помощью растровой электронной микроскопии (РЭМ) поперечных сечений, что дало номинальные толщины 2, 3 и 4 мкм. Для определения трибологических характеристик в условиях сухого скольжения использовался трибометр типа «палец – диск». Контролем служил шар из твердого сплава (диаметром 6 мм). При контролируемых температурах окружающей среды 40, 45 и 50 °С прикладывались нормальные нагрузки 5, 10 и 15 Н, что обеспечивало воспроизводимые условия испытаний.

Объем изношенного материала рассчитывали с помощью интерферометрической профилометрии на основе белого света по дорожке износа, а удельную интенсивность изнашивания (W_s) вычисляли по формуле

$$W_s = \frac{V}{(F - L)}, \quad (1)$$

где V – объем изношенного материала (мм³); F – нормальная нагрузка, Н; L – путь трения, м.

Условия эксперимента повторяли трижды с целью обеспечения статистической надежности, и для дальнейшего анализа использовалась средняя интенсивность изнашивания. После проверки качества данных и удаления резко выделяющихся значений экспериментальных величин и противоречивых результатов измерений для моделирования было отобрано 28 экспериментальных результатов. Подобные экспериментальные процедуры широко используются в трибологических исследованиях покрытых систем [18, 19]. План эксперимента охватывает четыре фактора: тип покрытия, температура (40, 45, 50 °С), контактная нагрузка (5, 10, 15 Н) и толщина покрытия (2, 3, 4 мкм). В табл. 1 представлены различные факторы и их диапазоны.

Предлагаемое исследование основано на трехуровневой гибридной аналитической модели, которая объединяет традиционные методы планирования эксперимента (design of experiment, DoE) и управляемые данными модели машинного обучения (machine learning, ML) для обеспечения надежного и интерпретируемого прогнозирования износа. Структура разработана последовательно, причем каждый уровень предоставляет дополнительную информацию и обеспечивает перекрестную проверку (CV – cross-validation). Уровень 1 (анализ Taguchi) позволяет проводить быструю сортировку (скрининг) влияющих параметров в сценариях, устойчивых к шумам; уровень 2 (response surface methodology, RSM) строит непрерывную эмпирическую модель и проверяет ее статистическую значимость; уровень 3 (регрессия на основе машинного обучения) улавливает нелинейные взаимодействия и обеспечивает обобщение и интерпретацию важности признаков [20–25]. На сегодняшний

Таблица 1

Table 1

Управляющие факторы и их уровни

Control factors and levels

Фактор	Уровень 1	Уровень 2	Уровень 3
Тип покрытия	AlTiN, CrN, TiC	AlTiN, CrN, TiC	AlTiN, CrN, TiC
Температура, T , °С	40	45	50
Нагрузка, L , Н	5	10	15
Толщина, K , мкм	2	3	4

день гибридный подход, объединяющий статистические методы и машинное обучение, считается наиболее эффективным для моделирования многофакторных трибологических систем [26, 27].

На рис. 1 показан весь аналитический процесс: все три уровня применяются к одному и тому же набору данных ($n = 28$), что гарантирует согласованность и сопоставимость результатов между подходами. Краткая сводка этой трехуровневой методологии приведена в табл. 2.

Метод Taguchi позволяет находить оптимальный набор параметров для каждой характеристики производительности путем анализа отношения сигнал/шум (S/N). Taguchi использовал отношение S/N в качестве характеристики качества процесса. Отношение S/N по принципу «чем меньше, тем лучше» преобразует измененные значения интенсивности изнашивания в устойчивую к шумам статистическую характеристику качества, которая одновременно учитывает среднее значение отклика и его дисперсию.

Уравнение Taguchi для этого принципа имеет вид

$$\frac{S}{N} = -10 \log \frac{1}{n} \left(\sum y^2 \right), \quad (2)$$

где y – наблюдаемые данные; n – количество наблюдений.

Методология поверхности отклика (RSM) предоставляет статистическую эмпирическую модель, использующую полиномы низких порядков для аппроксимации экспериментальных данных. Это позволяет визуализировать поверхность отклика и определять значимость факторов с помощью дисперсионного анализа (ANOVA) [13]. Цель моделирования – установить корреляцию между переменными отклика и независимыми переменными. В настоящей работе экспериментальные результаты аппроксимированы полиномиальной регрессионной моделью второго порядка:

$$Y = a_0 + \sum_{i=1}^k a_i x_i + \sum_{i=1}^k a_{ii} x_i^2 + \sum_{i < j}^k a_{ij} x_i x_j, \quad (3)$$




Рис. 1. Трехуровневая аналитическая структура Taguchi-RSM-ML

Fig. 1. Three-tier Taguchi-RSM-ML analytical framework

Сводка трехуровневой аналитической методологии
Overview of the three-tier analytical methodology

Уровень	Метод	Ключевая математическая основа	Основные результаты
1	Анализ отношения сигнал/шум Taguchi	$\eta = -10 \cdot \log_{10}(v^2)$ (принцип «чем меньше, тем лучше»)	Отношения сигнал/шум; ранжирование главных эффектов; оптимальные уровни
2	Методология поверхности отклика	Полная квадратичная модель (МНК, 11 членов); дисперсионный анализ типа II	Полиномиальное уравнение; таблица дисперсионного анализа; R^2 ; поверхности отклика
3a	Градиентный бустинг	Последовательное бустирование 200 деревьев; $L2$ -регуляризация функции потерь	$CV R^2$, RMSE, MAE; важность признаков по Джини
3b	Случайный лес	Ансамбль деревьев решений; 200 деревьев; экспоненциальное взвешивание потерь	$CV R^2$, RMSE, MAE; прогнозирование
3c	Интерпретируемость SHAP	Аддитивные атрибуции Шепли; бэкенд TreeExplainer	Значения SHAP для каждого признака; направленная атрибуция
Наилучший вариант	Комбинаторная оптимизация на основе ML	Полный перебор 81 дискретной конфигурации	Глобально оптимальные параметры; минимальное прогнозируемое значение износа $\hat{S}$

где Y – искомый отклик; a_0 – свободный член; a_i , a_{ii} , и a_{ij} – коэффициенты при линейных, квадратичных членах и членах взаимодействия соответственно; x_i – кодированные независимые переменные.

Для оценки параметров модели методом обыкновенных наименьших квадратов (МНК) использовалась библиотека statsmodels (v0.14). Построена таблица дисперсионного анализа с суммой квадратов типа II для проверки статистической значимости каждого члена модели при уровне значимости 5 % ($p < 0,05$). Качество модели оценивалось по следующим критериям: коэффициент детерминации R^2 , скорректированный R^2 , среднеквадратичная ошибка (RMSE), тест на нормальность остатков (Omnibus) и критерий Дарбина – Уотсона (автокорреляция остатков).

Подготовка данных для машинного обучения. Категориальная переменная «тип покрытия» была преобразована с помощью прямого

кодирования (one-hot encoding) с удалением первого столбца для избегания мультиколлинеарности. В результате созданы два бинарных индикатора: Coating_CrN и Coating_TiC, при этом AlTiN выступает в качестве неявной эталонной категории. Итоговая матрица признаков для моделей ML включает в себя пять столбцов: температура (T), нагрузка (L), толщина покрытия (K), Coating_CrN и Coating_TiC. Для древовидных моделей (градиентный бустинг, AdaBoost, случайный лес), инвариантных к масштабированию, дополнительная нормализация признаков не выполнялась.

Для реализации алгоритмов регрессии использовались библиотеки scikit-learn, LightGBM и TensorFlow. Ниже описаны примененные модели.

Градиентный бустинг (Gradient boosting) – ансамбль из 200 деревьев, строящихся последовательно: каждое новое дерево оптимизируется по отрицательному градиенту (псевдоостаткам)

функции потерь L_2 . Максимальная глубина деревьев – 6, скорость обучения (learning rate) – 0,05 для баланса смещения и дисперсии. Метод эффективен на небольших выборках благодаря возможности ранней остановки при тестировании на удерживаемых фолдах [15].

AdaBoost – адаптивный бустинг-ансамбль из 200 деревьев, перераспределяющий веса ошибочно предсказанных образцов, что заставляет алгоритм последовательно фокусироваться на сложных примерах. Вклад последующих деревьев регулируется скоростью обучения 0,05. Сообщается, что *AdaBoost* демонстрирует высокую обобщающую способность на малых табличных данных [16].

Случайный лес (Random forest) – бэггинг-модель из 200 деревьев решений, обученных на случайных подвыборках данных и случайных наборах признаков. Параметры: максимальная глубина – 15, минимальное количество образцов для разбиения узла (min_samples_split) – 5. В отличие от бустинга случайный лес усредняет результаты независимых деревьев, уменьшая дисперсию и сохраняя интерпретируемость. Оценка ошибки «вне мешка» (out-of-bag) дает объективные показатели перекрестной проверки. Метод устойчив на малых выборках и не страдает от проблем сходимости, характерных для глубокого обучения [17].

Выбор гиперпараметров. Гиперпараметры всех ML-моделей выбраны на основе комбинации рекомендаций из литературы и предварительных экспериментов. Для градиентного бустинга принято 200 деревьев, скорость обучения 0,05 и максимальная глубина 6, что согласуется с рекомендациями Фридмана (2001) для баланса смещения и дисперсии на малых выборках. Для случайного леса использовано 200 деревьев, глубина 15 и минимальное количество образцов для разбиения узла (min_samples_split) 5 – это типичные настройки для табличных наборов данных малого и среднего размера. Для *AdaBoost* выбрано 200 слабых классификаторов со скоростью обучения 0,05 для обеспечения постепенной сходимости.

Формальный поиск по сетке (grid search) не проводился, поскольку исчерпывающая настройка гиперпараметров на малом наборе данных ($n = 28$) может привести к переобучению на блоках данных для проверки (validation folds).

Анализ чувствительности с варьированием количества деревьев (например, 50, 100, 200, 500) также не выполнялся. Однако консервативная скорость обучения 0,05 по своей сути ограничивает предельный вклад поздних деревьев, снижая чувствительность к точному числу деревьев. Вместо системного подбора использованы консервативные значения гиперпараметров, обоснованные в литературе по ансамблевым методам для небольших выборок.

Каждая модель машинного обучения оценивалась с применением стратифицированной пятикратной перекрестной проверки (KFold, n_splits = 5, shuffle = True, random_state = 42). Такой протокол обеспечивает объективную оценку обобщающей способности модели на небольших наборах данных: выборка из 28 наблюдений разделяется на пять непересекающихся блоков данных (folds), каждый из которых поочередно выступает в роли проверочного. Это позволяет тестировать модель на данных, не участвовавших в обучении.

Для оценки качества прогнозирования использовались три взаимодополняющие метрики, рассчитываемые по следующим формулам:

$$R^2 = 1 - \frac{\sum_{i=1}^n (z_i - \hat{z}_i)^2}{\sum_{i=1}^n (z_i - \bar{z})^2}, \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (z_i - \hat{z}_i)^2}, \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |z_i - \hat{z}_i|, \quad (6)$$

где n – количество образцов; z_i – фактическое значение; $\hat{z}_i$ – прогнозируемое значение.

Коэффициент детерминации R^2 измеряет долю дисперсии интенсивности изнашивания, объясняемую моделью. Среднеквадратичная ошибка (RMSE) придает больший вес крупным индивидуальным ошибкам прогнозирования по сравнению со средней абсолютной ошибкой (MAE). Таким образом, эти две метрики взаимодополняют друг друга, позволяя охарактеризовать как систематические отклонения, так и влияние выбросов. Все метрики представлены в виде среднего значения плюс-минус стандартное отклонение по пяти блокам данных (folds).

После завершения перекрестной проверки наиболее успешная модель (градиентный бустинг) была заново обучена на всем наборе данных из 28 наблюдений. Для глобального ранжирования переменных извлечена важность признаков на основе примеси Джини (суммарное взвешенное уменьшение функции потерь, вносимое каждой переменной во всех 200 деревьях бустинга). Для дополнения этой глобальной меры атрибуцией на уровне отдельных наблюдений рассчитаны SHAP-значения (SHapley Additive exPlanations) с использованием бэкенда TreeExplainer библиотеки shap [21]. SHAP-значения представляют собой средний предельный вклад каждого признака, усредненный по всем возможным порядкам включения признаков, что обеспечивает теоретически обоснованное аддитивное разложение индивидуальных прогнозов.

Результаты и их обсуждение

Выборка значений отношения сигнал/шум (S/N) представлена в табл. 3. Средние отношения S/N для покрытий AlTiN, CrN и TiC составляют 36,64, 30,33 и 26,74 дБ соответственно, что однозначно указывает на AlTiN как на наилучшее покрытие с точки зрения износостойкости. Наивысшее индивидуальное отношение S/N (38,49 дБ) зафиксировано для покрытия AlTiN

при 45 °С, нагрузке 10 Н и толщине 3 мкм; этот результат воспроизведен в повторных экспериментах (опыты № 1 и 19), что подтверждает воспроизводимость методики.

Анализ динамического диапазона показывает, что покрытия TiC (10,3 дБ) и CrN (10,0 дБ) более чувствительны к изменению технологических параметров, чем AlTiN (7,7 дБ). Для CrN повышение температуры с 40 до 50 °С вызывает снижение отношения S/N примерно на 4 дБ, что свидетельствует об интенсификации окислительного изнашивания при увеличении температуры – явлении, ранее отмеченном для деградации нитридных покрытий [22]. Напротив, TiC демонстрирует наибольшую скорость изменения отношения S/N при росте нагрузки ($\approx -3,5$ дБ / 5 Н), что указывает на склонность этого материала к хрупкому разрушению при высоких контактных нагрузках [9]. Таким образом, химический состав покрытия является наиболее значимым фактором, определяющим износостойкость по данным анализа Taguchi, что согласуется с известными трибологическими данными [14].

Построенная RSM-модель второго порядка является хорошим предиктором интенсивности изнашивания: $R^2 = 0,901$, скорректированный $R^2 = 0,834$. Это означает, что модель объясняет около 90 % изменчивости отклика. Статистическая надежность модели подтверждается диа-

Таблица 3

Table 3

Выборочные значения отношения S/N по методу Taguchi (принцип «чем меньше, тем лучше»)

Selected Taguchi S/N ratio values (smaller-is-better)

Опыт №	Покрытие	Температура, °С	Нагрузка, Н	Толщина, мкм	Интенсивность изнашивания, мм ³ /(Н·м)	Отношение S/N , дБ
1	AlTiN	45	10	3	0,0119	38,49
11	AlTiN	45	15	3	0,0131	37,65
23	AlTiN	40	10	3	0,0127	37,92
7	CrN	45	10	3	0,0204	33,81
9	CrN	40	15	4	0,0179	34,94
6	TiC	45	10	3	0,0289	30,78
10	TiC	50	15	4	0,0252	31,97
15	CrN	50	5	2	0,0578	24,76
3	CrN	40	5	4	0,0489	26,21
8	TiC	50	5	4	0,0674	23,43

гностикой остатков: тест Omnibus ($p = 0,088$) и статистика Дарбина – Уотсона (2,52) указывают на выполнение допущений о нормальности и независимости остатков.

Результаты дисперсионного анализа (табл. 4) показывают, что наиболее значимым параметром является контактная нагрузка ($p < 0,001$), за которой следует химический состав покрытия ($p < 0,05$). Доминирование нагрузки имеет физическое объяснение: именно нагрузка определяет контактное напряжение и подповерхностную деформацию – ключе-

вые движущие механизмы изнашивания [25]. Статистическая значимость химического состава покрытия также подтверждает важность собственных свойств материала. Температура и толщина покрытия не являются статистически значимыми в исследованном диапазоне, что, вероятно, объясняется узким интервалом температур (40...50 °C). Этот результат согласуется с данными из литературы, согласно которым износ PVD-покрытий становится термически активируемым только при значительно более высоких температурах [26].

Таблица 4

Table 4

Дисперсионный анализ типа II для полной RSM-модели второго порядка

Type-II ANOVA table for the full second-order RSM model

Источник	Сумма квадратов	Ст. св.	F-значение	p-значение
T (температура)	0,000032	1	0,547	0,470
L (нагрузка)	0,002428	1	41,576	< 0,001
K (толщина)	0,000014	1	0,233	0,636
C_1 (покрытие CrN)	0,000412	1	7,056	0,017
C_2 (покрытие TiC)	0,000265	1	4,532	0,049
T^2	0,000006	1	0,106	0,749
L^2	0,000243	1	4,162	0,058
K^2	0,000035	1	0,599	0,450
$T \times L$	0,000050	1	0,861	0,367
$T \times K$	0,000041	1	0,694	0,417
$L \times K$	0,000014	1	0,242	0,629
Остаток	0,000934	16	—	—

Подобранное уравнение регрессии второго порядка (в кодированных переменных) имеет следующий вид:

$$Y = 0,0146 + 0,0012T - 0,0162L - 0,0010K + 0,0123C_1 + 0,0146C_2 - 0,0013T^2 + 0,0101L^2 + 0,0031Th^2 - 0,0024TL + 0,0032TK - 0,0013LK. \quad (7)$$

Отрицательный коэффициент при нагрузке (–0,0162) на первый взгляд указывает на положительную корреляцию между прогнозируемой интенсивностью изнашивания и увеличением нагрузки. Однако эта кажущаяся аномалия требует осторожной интерпретации.

Хотя экспериментальная матрица базировалась на ортогональном массиве Taguchi L_{27} для

трех непрерывных факторов (температура, нагрузка, толщина), категориальный фактор «тип покрытия» не был полностью перекрестно сопоставлен со всеми комбинациями уровней. После проверки качества, сократившей набор данных до 28 опытов, исходный план утратил строгую ортогональность: непропорционально большое количество условий с высокой нагрузкой (15 Н) оказалось ассоциировано с образцами AlTiN, которые по своей природе демонстрируют более низкую интенсивность изнашивания.

Это представляет собой реальное ограничение планирования эксперимента, а не просто статистический артефакт. Неортогональность матрицы вносит систематическую корреляцию между нагрузкой и типом покрытия, в результате чего регрессия приписывает часть низкой

интенсивности изнашивания, присущей AlTiN, увеличению нагрузки.

В настоящем исследовании не применялись постфактум меры балансировки (например, анализ фактора инфляции дисперсии, декомпозиция суммы квадратов типа III или корректировка на ковариаты) для смягчения этого смешивания. В будущих работах следует использовать сбалансированный полный факторный план либо *D*-оптимальный план с равной повторяемостью для всех комбинаций покрытия и нагрузки – это позволит устранить смешивание и обеспечить однозначную оценку основных эффектов.

Соответственно, указанный коэффициент следует интерпретировать с осторожностью и не рассматривать как доказательство прямой физической зависимости, согласно которой более высокие нагрузки приводят к меньшей интенсивности изнашивания.

Положительные коэффициенты для CrN и TiC подтверждают повышенную интенсивность изнашивания по сравнению с AlTiN, что согласуется с их относительно более низкой стойкостью к окислению и вязкостью разрушения. Квадратичный член нагрузки является почти значимым ($p \approx 0,058$, согласно табл. 4), что указывает на слабую нелинейность и, возможно, на переходное поведение при высоких нагрузках.

На рис. 2 и 3 показаны соответственно поверхность отклика RSM и контурный график,




Рис. 2. Поверхность отклика RSM: интенсивность изнашивания в зависимости от нагрузки и температуры (AlTiN, 3 мкм)

Fig. 2. RSM surface: wear rate vs load and temperature (AlTiN, 3 μm)




Рис. 3. Контурная карта RSM

Fig. 3. RSM contour map

которые наглядно демонстрируют доминирование нагрузки и сравнительно незначительное влияние температуры. График фактических значений против прогнозируемых (рис. 4) показывает хорошее согласие вдоль линии 45°, что подтверждает точность модели.

В табл. 5 представлены результаты перекрестной проверки моделей машинного обучения. Случайный лес показал наивысшую точность при перекрестной проверке ($R^2 = 0,7551$), что свидетельствует о его высокой обобщающей способности. Градиентный бустинг продемонстрировал наилучшую производительность на




Рис. 4. График прогнозируемой RSM интенсивности изнашивания в сравнении с фактической

Fig. 4. RSM predicted versus actual wear rate plot

Метрики перекрестной проверки и обучения на полных данных (модели ML)

Cross-validated vs. full-data metrics (ML models)

Модель	Средний CV R^2	R^2 на полных данных	Средняя RMSE	Средняя MAE
Градиентный бустинг	0,6467	0,9132	0,00984	0,00833
Случайный лес	0,7551	0,8776	0,00757	0,00641
AdaBoost	0,6972	0,9019	0,00865	0,00712

полном наборе данных ($R^2 = 0,9132$), поэтому он наиболее подходит для задач оптимизации. AdaBoost занял промежуточное положение, показав стабильные результаты. Это подтверждает применимость ансамблевых методов для трибологических задач с ограниченным объемом данных, где надежность и контроль дисперсии имеют первостепенное значение [25, 28].

Важно отметить, что модели машинного обучения демонстрируют более высокую обобщающую способность при перекрестной проверке по сравнению с RSM, которая, в свою очередь, лучше аппроксимирует данные внутри выборки. Это отражает дополнительные преимущества гибридного подхода к моделированию.

Анализ остатков модели градиентного бустинга (рис. 5) показывает, что их распределение симметрично относительно нуля без признаков

гетероскедастичности или систематического смещения, что говорит об адекватности модели. Тенденция к кластеризации остатков в области низких значений интенсивности изнашивания объясняется тем, что в этой области преобладают данные для покрытия AlTiN. Аналогично диагностика остатков RSM подтверждает выполнение допущений о нормальности и независимости, что указывает на способность обеих моделей адекватно описывать структуру данных.

На рис. 6 показано, что наиболее важным фактором, определяющим интенсивность изнашивания, является контактная нагрузка, за которой следует химический состав покрытия. Этот вывод согласуется с результатами анализа Taguchi и дисперсионного анализа, что демонстрирует высокую согласованность между методологиями. Невысокая значимость темпе-




Рис. 5. График остатков (модель градиентного бустинга)

Fig. 5. Residual plot (Gradient boosting model)




Рис. 6. Оценка важности признаков по критерию Джини (Gini importance) для модели градиентного бустинга

Fig. 6. Gini-based feature importance scores

ратуры и толщины в исследованном диапазоне также подтверждает их ограниченную роль. Эти результаты согласуются с другими исследованиями, которые определили свойства материала и условия нагружения в качестве основных факторов, влияющих на износ [16, 25].

SHAP-анализ (рис. 7) позволяет детально проанализировать вклады отдельных признаков. Покрытия TiC и CrN демонстрируют положительные значения SHAP, указывая на более высокую интенсивность изнашивания, тогда как AlTiN показывает отрицательные вклады, что вновь подтверждает его превосходство. Контактная нагрузка оказывает положительный, но немонотонный эффект на износ. Толщина также демонстрирует немонотонное поведение, что предполагает существование оптимального диапазона толщин. Физически это объясняется балансом между эффектами подложки (для тонких покрытий) и остаточными напряжениями (для толстых покрытий) [23].

Высокая согласованность между результатами SHAP, коэффициентами RSM и анализом Taguchi обеспечивает надежную перекрестную проверку и повышает уверенность в физической значимости полученных результатов.

Анализ кривых обучения (рис. 8) показывает, что производительность модели увеличивается с ростом размера обучающей выборки без признаков насыщения. Разница между тренировочной и проверочной производительностью постепенно сокращается, что указывает на потенциал дальнейшего повышения обобщающей способности при увеличении объема данных. Экстраполяция




Рис. 7. Сводный график SHAP

Fig. 7. SHAP summary plot




Рис. 8. Кривые обучения

Fig. 8. Learning curves

позволяет предположить, что добавление 30–50 наблюдений могло бы повысить $CV R^2$ выше 0,85, подчеркивая важность расширения набора данных для улучшения точности прогнозирования.

Использование 200 деревьев всего на 28 наблюдениях требует тщательного рассмотрения риска переобучения. Был принят ряд мер предосторожности:

- пятикратная перекрестная проверка обеспечивает несмещенную оценку производительности на данных, не участвовавших в обучении;
- скорость обучения консервативно установлена на уровне 0,05, что требует многих итераций для сходимости и, таким образом, действует как неявная регуляризация;
- максимальная глубина деревьев ограничена (6 для градиентного бустинга, 15 для случайного леса), чтобы предотвратить запоминание отдельных образцов.

Анализ чувствительности по отношению к количеству деревьев не проводился; в будущих работах следует систематически оценивать влияние размера ансамбля на прогностическую стабильность для небольших трибологических наборов данных.

Более простые линейные модели с регуляризацией (LASSO, Ridge, Elastic Net) не были включены в настоящее исследование, поскольку основное внимание уделялось ансамблевым методам на основе деревьев; их включение в будущих сравнительных исследованиях желательно.

Независимый отложенный тестовый набор не выделялся; вместо этого весь набор данных был использован для перекрестной проверки, что является стандартной практикой для малых выборок ($n < 50$), но ограничивает оценку внешней обобщаемости.

Прогнозируемая оптимальная конфигурация (AlTiN, 4 мкм, 50 °C, 15 Н) не была проверена экспериментально; будущие работы должны включать в себя подтверждающие эксперименты для проверки прогнозов модели.

Основанная на ML оптимизация определила следующую конфигурацию как оптимальную: покрытие AlTiN, толщина 4 мкм, температура 50 °C, нагрузка 15 Н. Прогнозируемая интенсивность изнашивания для этой конфигурации составляет 0,010823 мм³/(Н·м) (табл. 6). Хотя это условие не было проверено экспериментально,

оно является глобальным оптимумом в рамках рассмотренного пространства проектирования.

Важно отметить, что все три метода – Taguchi, RSM и ML – согласованно выбирают AlTiN в качестве наилучшего покрытия, что обеспечивает надежную междисциплинарную поддержку. Небольшое расхождение между результатами ML и метода Taguchi (~8,2 %) находится в пределах экспериментальной неопределенности.

Локализация оптимальных конфигураций вокруг AlTiN может указывать на то, что поверхность отклика вблизи оптимума относительно плоская, это предполагает устойчивость системы к умеренным вариациям параметров. С промышленной точки зрения такая устойчивость означает, что покрытия AlTiN могут продолжать надежно работать даже при умеренных изменениях рабочих условий.

Таблица 6

Table 6

Метрики перекрестной проверки и обучения на полных данных (модели ML)

Cross-validated vs. full-data metrics (ML models)

Ранг	Покрытие	Температура, °C	Нагрузка, Н	Толщина, мкм	Прогнозируемая интенсивность изнашивания, мм ³ /(Н·м)
1 (оптимум)	AlTiN	50	15	4	0,010823
2	AlTiN	50	15	3	0,011105
3	AlTiN	40	15	4	0,012080

Выводы

Разработана и применена трехуровневая гибридная аналитическая методология, объединяющая анализ отношения сигнал/шум по методу Taguchi, методологию поверхности отклика (RSM) и регрессионные модели машинного обучения (ML), для прогнозирования и оптимизации изнашивания твердых PVD-покрытий.

Метод Taguchi позволил идентифицировать AlTiN как наилучшее покрытие при температуре 45 °C, нагрузке 10 Н и толщине 3 мкм с высоким отношением S/N , равным 38,49 дБ.

Модель RSM второго порядка продемонстрировала высокую прогностическую способность ($R^2 = 0,901$) и была статистически значимой ($p < 0,001$). Дисперсионный анализ показал, что доминирующими факторами служат контактная нагрузка и химический состав покрытия, тогда

как температура и толщина не были значимыми в исследованном диапазоне. Полученное регрессионное уравнение является физически интерпретируемым и вычислительно эффективным для прогнозирования изнашивания и анализа чувствительности.

Среди моделей машинного обучения градиентный бустинг показал наилучшую прогностическую точность, тогда как случайный лес и AdaBoost продемонстрировали более высокую обобщающую способность при перекрестной проверке. Как анализ важности по Джини, так и SHAP-анализ последовательно определили химический состав покрытия в качестве наиболее значимого параметра, за которым следует контактная нагрузка. SHAP дополнительно выявил нелинейные, немонотонные эффекты – особенно для толщины покрытия, – обеспечивая более глубокое физическое понимание

по сравнению с традиционными статистическими моделями.

Важно отметить, что все три методологии (Taguchi, RSM и ML) согласованно определили AlTiN как наилучшее покрытие. Тесное согласие между прогнозами ML и экспериментальными результатами Taguchi (отклонение ~8,2 %) подтверждает надежность и валидность предложенной гибридной структуры.

Оптимизация на основе машинного обучения предсказала глобальный оптимум для покрытия AlTiN при толщине 4 мкм, температуре 50 °C и нагрузке 15 Н, с прогнозируемой интенсивностью изнашивания 0,010823 мм³/(Н·м).

Список литературы

1. Intelligent tool wear monitoring using XGBoost, SVR, and DNN models in NMQLE environment / O. Almomani, B. Venkatesh, S.P. Chaudhary, A. Mishra, S. Sujai, S. Juneja, P. Pradhan, S.P. Venkatesan, A. Bhowmik, Y. Tamene // *Scientific Reports*. – 2026. – Vol. 16 (1). – P. 10030. – DOI: 10.1038/s41598-026-40968-8.
2. Deep learning prediction of dry friction in DLC coatings using literature-derived data / O. Cherguy, R. Chmielowski, E. Hachem, I. Lahouij // *Tribology Letters*. – 2025. – Vol. 73 (4). – P. 125. – DOI: 10.1007/s11249-025-02056-2.
3. Daghbouch A., Louhichi B., Terres M.A. Optimization and prediction of mass loss during adhesive wear of nitrided AISI 4140 steel parts // *Crystals*. – 2025. – Vol. 15 (10). – P. 875. – DOI: 10.3390/cryst15100875.
4. Influence of the interlayer and the substrate on the wear behavior of PVD tool coatings during turning of C60+ N / B. Bergmann, B. Denkena, N. Junge, C. Kalscheuer, K. Bobzin, X. Liu // *Wear*. – 2026. – Vol. 584–585. – P. 206396. – DOI: 10.1016/j.wear.2025.206396.
5. Minimizing thin film thickness in TiN coatings using genetic algorithms / M.I. Jarrah, A.S.M. Jaya, M.A. Azam, M.R. Muhamad, H. Akbar // *AIP Conference Proceedings*. – 2018. – Vol. 2016 (1). – P. 020061. – DOI: 10.1063/1.5055463.
6. Ambhore N., Naranje V., Shelke S. Machining performance evaluation in turning of hardened steel using machine learning // *Materials and Manufacturing Processes*. – 2025. – Vol. 40 (14). – P. 1935–1942. – DOI: 10.1080/10426914.2025.2559622.
7. Fuzzy rule-based model to estimate surface roughness and wear in hard coatings / A.S.M. Jaya, S.Z.M. Hashim, H. Haron, M.R. Muhamad, M.N.A. Rahman // *Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics*. – IEEE, 2012. – P. 1076–1081. – DOI: 10.1109/ICSMC.2012.6377873.
8. Jiang J., Omar I., Khan M. Predicting wear damage in moving mechanical contacts: Comparative analysis of regression algorithms and feature selection techniques // *ISA Transactions*. – 2025. – Vol. 167. – P. 675–687. – DOI: 10.1016/j.isatra.2025.08.027.
9. Kahraman F., Sugözü B. An integrated approach based on the Taguchi method and response surface methodology to optimize parameter design of asbestos-free brake pad material // *Turkish Journal of Engineering*. – 2019. – Vol. 3 (3). – P. 127–132. – DOI: 10.31127/TUJE.479458.
10. Wear resistance prediction of AlCoCrFeNi-X (Ti, Cu) high-entropy alloy coatings based on machine learning / J. Kang, Y. Niu, Y. Zhou, Y. Fan, G. Ma // *Metals*. – 2023. – Vol. 13 (5). – P. 939. – DOI: 10.3390/met13050939.
11. Machine learning predictive modeling of plasma-sprayed lanthanum zirconate coatings / S. Karthikeyan, R. Prasanna, V. Balasubramanian, G. Perumal, V. Mugendiran // *Surface Engineering*. – 2025. – Vol. 41 (10–12). – P. 1045–1054. – DOI: 10.1177/02670844251389512.
12. Application of machine learning to solid particle erosion of APS-TBC and EB-PVD TBC at elevated temperatures / Y. Liu, R. Ravichandran, K. Chen, P. Patnaik // *Coatings*. – 2021. – Vol. 11 (7). – P. 845. – DOI: 10.3390/coatings11070845.
13. A review of explainable AI methods and their application in manufacturing systems / G. Tzisionis, P. Mouratidis, G. Kougka, I. Gialampoukidis, S. Vrochidis, I. Kompatsiaris, M. Vlachopoulou // *Discover Applied Sciences*. – 2025. – Vol. 8. – P. 52. – DOI: 10.1007/s42452-025-07908-z.
14. Machine learning and Taguchi techniques for predicting wear mechanisms of Ni–Cu alloy composites / J. Kumaraswamy, Thirumalesh, A.S. Ashok, N.B. Shankar, S.R. Praveen // *Results in Surfaces and Interfaces*. – 2024. – Vol. 17. – DOI: 10.1016/j.rsufi.2024.100307.
15. Mallick A., Sahu R.K., Gangi Setti S. Machine learning enabled hardness prediction in centrifugal cast functionally graded materials for superior wear performance // *Journal of Tribology*. – 2025. – Vol. 148 (3). – P. 031701. – DOI: 10.1115/1.4069854.
16. Tribo-informatics approach to predict wear and friction coefficient of Mg/Si₃N₄ composites using machine learning techniques / M.B. Pasha, R.N. Rao, S. Ismail, M. Gupta, P.S. Prasad // *Tribology International*. – 2024. – Vol. 196. – P. 109696. – DOI: 10.1016/j.triboint.2024.109696.
17. Patel K. Material lifespan predictor // *International Journal of Research in Science and Technology*. –

2025. – Vol. 15 (4). – P. 31–41. – DOI: 10.37648/ijrst.v15i04.004.

18. Mechanical and tribological behavior of LM26/SiC/Ni-Gr hybrid composites / S.Y. Pawar, J. Haider, G. Pintaude, S.M. Sekar, V. Kolhe, K. Chandratre, S. Sonawane, P. Ritapure // *Journal of Composites Science*. – 2023. – Vol. 7 (4). – P. 159. – DOI: 10.3390/jcs7040159.

19. Radhika N., Sabarinathan M., Sivaraman S. A comparative analysis of machine learning techniques for predicting the wear rate of ceramic coated steel // *IEEE Access*. – 2024. – Vol. 12. – P. 146949–146967. – DOI: 10.1109/access.2024.3473028.

20. Predictions and mechanism analyses of the fatigue strength of steel based on machine learning / F. Yan, K. Song, Y. Liu, S. Chen, J. Chen // *Journal of Materials Science*. – 2020. – Vol. 55 (31). – P. 15334–15349. – DOI: 10.1007/s10853-020-05091-7.

21. Explainable machine learning in materials science / X. Zhong, B. Gallagher, S. Liu, B. Kailkhura, A. Hiszpanski, T.Y.-J. Han // *Npj. Computational Materials*. – 2022. – Vol. 8. – DOI: 10.1038/s41524-022-00884-7.

22. Towards an explainable multi-target regression for wear and friction prediction for brake pad materials / A. Sellami, M. Rekik, C.B. Njemma, R. Elleuch // *Acta Polytechnica Hungarica*. – 2024. – Vol. 21 (11). – P. 155–174. – DOI: 10.12700/aph.21.11.2024.11.9.

23. Tool wear mechanism and prediction in milling TC18 titanium alloy using deep learning / J. Ma, D. Luo,

X. Liao, Z. Zhang, Y. Huang, J. Lu // *Measurement*. – 2021. – Vol. 173. – P. 108554. – DOI: 10.1016/j.measurement.2020.108554.

24. AI-driven wear monitoring of PVD TiAlN coated carbide insert in sustainable machining of Hastelloy C276: An industry 4.0 perspective / B. Sen, S. Saha, R. Kumar, R. Jhala, N. Patil, A. Mahapatro, A. Bhowmik, A. Santhosh // *Results in Engineering*. – 2025. – Vol. 25. – P. 104457. – DOI: 10.1016/j.rineng.2025.104457.

25. Machine learning in wear prediction / R. Shah, N. Pai, G. Thomas, S. Jha, V. Mittal, K. Shirvni, H. Liang // *Journal of Tribology*. – 2024. – Vol. 147 (4). – P. 040801. – DOI: 10.1115/1.4066865.

26. High-temperature ablation resistance prediction of ceramic coatings using machine learning / J. Sun, Z. Zhang, Y. Zhang, X. Zhang, J. Guo, Q. Fu, L. Wu // *Journal of the American Ceramic Society*. – 2024. – Vol. 108 (1). – DOI: 10.1111/jace.20136.

27. Bridging fidelities to predict nanoindentation tip radii using interpretable deep learning models / C.O.W. Trost, S. Zak, S. Schaffer, C. Saringer, L. Exl, M.J. Cordill // *JOM*. – 2022. – Vol. 74 (6). – P. 2195–2205. – DOI: 10.1007/s11837-022-05233-z.

28. A tensile properties-related fatigue strength predicted machine learning framework for alloys used in aerospace / J. Fan, Z. Wang, C. Liu, D. Shi, X. Yang // *Engineering Fracture Mechanics*. – 2024. – Vol. 301. – DOI: 10.1016/j.engfracmech.2024.110057.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

© 2026 Авторы. Издательство Новосибирского государственного технического университета. Эта статья доступна по лицензии Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная (<https://creativecommons.org/licenses/by/4.0>).

Wear rate prediction of PVD hard coatings using a hybrid Taguchi–RSM–machine learning framework with SHAP-based interpretability

Umesh Subhash Patharkar^{1, a}, Sunil Apparao Patil^{1, b}, Nitin Ambhore^{2, c, *}

¹ Government Engineering College, Chh. Sambhajinagar, 431005, Maharashtra, India

² Vishwakarma Institute of Technology, SPPU, Pune 411037, Maharashtra, India

^a  <https://orcid.org/0009-0005-9303-641X>,  patharkarumeshsubhash@gmail.com; ^b  <https://orcid.org/0009-0000-4804-0720>,  sakpatil967@gmail.com;

^c  <https://orcid.org/0000-0001-8468-8057>,  nitin.ambhore@vit.edu

ARTICLE INFO

Article history:

Received: 06 April 2026

Revised: 11 April 2026

Accepted: 30 April 2026

Available online: 15 June 2026

Keywords:

PVD coatings

Wear

Response surface methodology

Random Forest

XGBoost

SHAP analysis

ABSTRACT

Introduction. The wear behaviour of physical vapour deposition (PVD) hard coatings is difficult to predict because of the nonlinear relationship between coating chemistry, deposition thickness, operating temperature, and applied contact load. Multi-dimensional parameter mapping through exhaustive experimentation is both time-consuming and costly. **The purpose of the work** is to implement a low-data hybrid architecture that combines Taguchi design, response surface methodology (RSM), and machine learning (ML) to predict and optimize wear performance based on a small dataset ($n = 28$). **Methods.** Three coating types – $AlTiN$, CrN , and TiC – were tested at temperature range of 40–50°C, contact load range of 5–15 N, and coating thickness range of 2–4 μm . Analysis of variance (ANOVA) was performed to identify the most influential parameter affecting wear. A predictive wear model was developed using response surface methodology. **Results and discussion.** ANOVA revealed that load and coating chemistry are the most influential factors affecting wear. Temperature and thickness were not found to be significant within the studied range. A RSM model was found statistically significant for predicting contact load and coating chemistry with $R^2 = 0.901$ ($Adj-R^2 = 0.834$, $RMSE = 0.0076$). Random forest (RF) had highest generalisation performance ($CV R^2 = 0.755$) and gradient boosting (GB) had the best overall fit ($R^2 = 0.913$) among the ML models tested using five-fold cross-validation. SHAP analysis indicated that coating chemistry formed the major contribution, then contact load, and little temperature contribution. Gradient boosting optimisation indicated that $AlTiN$ at 4 μm thickness, 15 N load and 50 °C are the preferred settings and the expected wear rate is 0.010823 (mm^3/Nm). The proposed framework demonstrates credible, interpretable wear forecasting using limited experimental data.

For citation: Patharkar U., Patil S., Ambhore N. Wear rate prediction of PVD hard coatings using a hybrid Taguchi–RSM–machine learning framework with SHAP-based interpretability. *Obrabotka metallov (tekhnologiya, oborudovanie, instrumenty) = Metal Working and Material Science*, 2026, vol. 28, no. 2, pp. 318–334. DOI: 10.17212/1994-6309-2026-28.2-318-334. (In Russian).

References

1. Almomani O., Venkatesh B., Chaudhary S.P., Mishra A., Sujai S., Juneja S., Pradhan P., Venkatesan S.P., Bhowmik A., Tamene Y. Intelligent tool wear monitoring using XGBoost, SVR, and DNN models in NMQL environment. *Scientific Reports*, 2026, vol. 16 (1), p. 10030. DOI: 10.1038/s41598-026-40968-8.
2. Cherguy O., Chmielowski R., Hachem E., Lahouij I. Deep learning prediction of dry friction in DLC coatings using literature-derived data. *Tribology Letters*, 2025, vol. 73 (4), p. 125. DOI: 10.1007/s11249-025-02056-2.
3. Daghbouch A., Louhichi B., Terres M.A. Optimization and prediction of mass loss during adhesive wear of nitrided AISI 4140 steel parts. *Crystals*, 2025, vol. 15 (10), p. 875. DOI: 10.3390/cryst15100875.
4. Bergmann B., Denkena B., Junge N., Kalscheuer C., Bobzin K., Liu X. Influence of the interlayer and the substrate on the wear behavior of PVD tool coatings during turning of C60+ N. *Wear*, 2026, vol. 584–585, p. 206396. DOI: 10.1016/j.wear.2025.206396.

* Corresponding author

Nitin Ambhore, Ph.D. (Engineering), Associate Professor
 Vishwakarma Institute of Technology,
 Pune - 411037, Maharashtra, India
 Tel.: +91-2026950441, e-mail: nitin.ambhore@vit.edu

5. Jarrah M.I., Jaya A.S.M., Azam M.A., Muhamad M.R., Akbar H. Minimizing thin film thickness in TiN coatings using genetic algorithms. *AIP Conference Proceedings*, 2018, vol. 2016 (1), p. 020061. DOI: 10.1063/1.5055463.
6. Ambhore N., Naranje V., Shelke S. Machining performance evaluation in turning of hardened steel using machine learning. *Materials and Manufacturing Processes*, 2025, vol. 40 (14), pp. 1935–1942. DOI: 10.1080/10426914.2025.2559622.
7. Jaya A.S.M., Hashim S.Z.M., Haron H., Muhamad M.R., Rahman M.N.A. Fuzzy rule-based model to estimate surface roughness and wear in hard coatings. *Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics*, 2012, pp. 1076–1081. DOI: 10.1109/ICSMC.2012.6377873.
8. Jiang J., Omar I., Khan M. Predicting wear damage in moving mechanical contacts: Comparative analysis of regression algorithms and feature selection techniques. *ISA Transactions*, 2025, vol. 167, pp. 675–687. DOI: 10.1016/j.isatra.2025.08.027.
9. Kahraman F., Sugözü B. An integrated approach based on the Taguchi method and response surface methodology to optimize parameter design of asbestos-free brake pad material. *Turkish Journal of Engineering*, 2019, vol. 3 (3), pp. 127–132. DOI: 10.31127/TUJE.479458.
10. Kang J., Niu Y., Zhou Y., Fan Y., Ma G. Wear resistance prediction of AlCoCrFeNi-X (Ti, Cu) high-entropy alloy coatings based on machine learning. *Metals*, 2023, vol. 13 (5), p. 939. DOI: 10.3390/met13050939.
11. Karthikeyan S., Prasanna R., Balasubramanian V., Perumal G., Mugendiran V. Machine learning predictive modeling of plasma-sprayed lanthanum zirconate coatings. *Surface Engineering*, 2025, vol. 41 (10–12), pp. 1045–1054. DOI: 10.1177/02670844251389512.
12. Liu Y., Ravichandran R., Chen K., Patnaik P. Application of machine learning to solid particle erosion of APS-TBC and EB-PVD TBC at elevated temperatures. *Coatings*, 2021, vol. 11 (7), p. 845. DOI: 10.3390/coatings11070845.
13. Tzionis G., Mouratidis P., Kougka G., Gialampoukidis I., Vrochidis S., Kompatsiaris I., Vlachopoulou M. A review of explainable AI methods and their application in manufacturing systems. *Discover Applied Sciences*, 2025, vol. 8, p. 52. DOI: 10.1007/s42452-025-07908-z.
14. Kumaraswamy J., Thirumalesh, Ashok A.S., Shankar N.B., Praveen S.R. Machine learning and Taguchi techniques for predicting wear mechanisms of Ni–Cu alloy composites. *Results in Surfaces and Interfaces*, 2024, vol. 17. DOI: 10.1016/j.rsufi.2024.100307.
15. Mallick A., Sahu R.K., Gangi Setti S. Machine learning enabled hardness prediction in centrifugal cast functionally graded materials for superior wear performance. *Journal of Tribology*, 2025, vol. 148 (3), p. 031701. DOI: 10.1115/1.4069854.
16. Pasha M.B., Rao R.N., Ismail S., Gupta M., Prasad P.S. Tribo-informatics approach to predict wear and friction coefficient of Mg/Si₃N₄ composites using machine learning techniques. *Tribology International*, 2024, vol. 196, p. 109696. DOI: 10.1016/j.triboint.2024.109696.
17. Patel K. Material lifespan predictor. *International Journal of Research in Science and Technology*, 2025, vol. 15 (4), pp. 31–41. DOI: 10.37648/ijrst.v15i04.004.
18. Pawar S.Y., Haider J., Pintaude G., Sekar S.M., Kolhe V., Chandratre K., Sonawane S., Ritapure P. Mechanical and tribological behavior of LM26/SiC/Ni-Gr hybrid composites. *Journal of Composites Science*, 2023, vol. 7 (4), p. 159. DOI: 10.3390/jcs7040159.
19. Radhika N., Sabarinathan M., Sivaraman S. A comparative analysis of machine learning techniques for predicting the wear rate of ceramic coated steel. *IEEE Access*, 2024, vol. 12, pp. 146949–146967. DOI: 10.1109/access.2024.3473028.
20. Yan F., Song K., Liu Y., Chen S., Chen J. Predictions and mechanism analyses of the fatigue strength of steel based on machine learning. *Journal of Materials Science*, 2020, vol. 55 (31), pp. 15334–15349. DOI: 10.1007/s10853-020-05091-7.
21. Zhong X., Gallagher B., Liu S., Kailkhura B., Hiszpanski A., Han T.Y.-J. Explainable machine learning in materials science. *Npj. Computational Materials*, 2022, vol. 8. DOI: 10.1038/s41524-022-00884-7.
22. Sellami A., Rekik M., Njemma C.B., Elleuch R. Towards an explainable multi-target regression for wear and friction prediction for brake pad materials. *Acta Polytechnica Hungarica*, 2024, vol. 21 (11), pp. 155–174. DOI: 10.12700/aph.21.11.2024.11.9.
23. Ma J., Luo D., Liao X., Zhang Z., Huang Y., Lu J. Tool wear mechanism and prediction in milling TC18 titanium alloy using deep learning. *Measurement*, 2021, vol. 173, p. 108554. DOI: 10.1016/j.measurement.2020.108554.
24. Sen B., Saha S., Kumar R., Jhala R., Patil N., Mahapatro A., Bhowmik A., Santhosh A. AI-driven wear monitoring of PVD TiAlN coated carbide insert in sustainable machining of Hastelloy C276: An industry 4.0 perspective. *Results in Engineering*, 2025, vol. 25, p. 104457. DOI: 10.1016/j.rineng.2025.104457.

25. Shah R., Pai N., Thomas G., Jha S., Mittal V., Shirvni K., Liang H. Machine learning in wear prediction. *Journal of Tribology*, 2024, vol. 147 (4), p. 040801. DOI: 10.1115/1.4066865.
26. Sun J., Zhang Z., Zhang Y., Zhang X., Guo J., Fu Q., Wu L. High-temperature ablation resistance prediction of ceramic coatings using machine learning. *Journal of the American Ceramic Society*, 2024, vol. 108 (1). DOI: 10.1111/jace.20136.
27. Trost C.O.W., Zak S., Schaffer S., Saringer C., Exl L., Cordill M.J. Bridging fidelities to predict nanoindentation tip radii using interpretable deep learning models. *JOM*, 2022, vol. 74 (6), pp. 2195–2205. DOI: 10.1007/s11837-022-05233-z.
28. Fan J., Wang Z., Liu C., Shi D., Yang X. A tensile properties-related fatigue strength predicted machine learning framework for alloys used in aerospace. *Engineering Fracture Mechanics*, 2024, vol. 301. DOI: 10.1016/j.engfracmech.2024.110057.

Conflicts of Interest

The authors declare no conflict of interest.

© 2026 The Authors. Published by Novosibirsk State Technical University. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0>).