

PRISM-MPWM: модель мира технологического процесса для диагностики износа инструмента по данным фрезерования

А.А. Лобко

Аннотация—Предложена модель PRISM-MPWM (Physics-Residual Invariant Support-aware Machine Process World Model) для оценки износа концевой фрезы по задней поверхности (VB). Модель не строит прогноз износа заново, а уточняет прогноз базовой модели по силам и моментам: обучаемый блок предсказывает только её остаточную ошибку, величина поправки ограничена, а вес поправки уменьшается при слабой поддержке обучающими данными и высокой неопределённости. Физическое ограничение запрещает уменьшение накопленного износа. Модель проверена на открытом наборе данных Denkena, Klemme и Stiehl: обучение и настройка выполнены на станках 1 и 2, станок 3 использован только для итоговой оценки. PRISM-MPWM снижает среднеквадратичную ошибку (RMSE) одношагового прогноза износа с 0,486 до 0,445 мкм, то есть на 8,45 % относительно базовой модели. Улучшение подтверждено групповым бутстрэпом по инструментам, снижением ошибки в зоне высокого износа, уменьшением недооценки высокого износа, отсутствием нарушений монотонности, прогнозом с отказом на трудных переходах и перестановочными контролями. Результат относится к диагностике износа по наблюдаемым сигналам и не распространяется на выбор режимов резания, для которого нужны записи с известными скоростью резания, подачей, глубиной и шириной фрезерования на каждом проходе.

Ключевые слова—износ инструмента, модель мира, неопределённость, остаточная модель, фрезерование, цифровой двойник.

1. ВВЕДЕНИЕ

Оценка износа инструмента при фрезеровании определяет качество поверхности, долю брака и сроки замены инструмента. Для практического применения недостаточно получить одно значение износа на следующем проходе VB_{k+1} . Система диагностики должна также указывать, в каких случаях прогноз опирается на достаточный объём обучающих данных, а в каких его следует передать оператору или более осторожной модели.

Распространённый подход состоит в прямом восстановлении следующего значения износа по признакам процесса с помощью нейронной сети. В работе используется другая постановка. Основной прогноз $\widehat{VB}_{k+1}^T$ даёт базовая модель по силам и моментам, а обучаемый блок моделирует только систематическую ошибку этого прогноза. Получаемая модель описывает переход состояния процесса: она объединяет базовый прогноз, поправку к нему, вес доверия к поправке, физическое ограничение и правило отказа от прогноза

при недостаточной поддержке данными (рис. 1).




Рис. 1. Схема модели PRISM-MPWM. Обучаемая часть (выделена цветом) только поправляет прогноз базовой модели и не может его заменить: остаток ограничивается величиной D_k , вес доверия g_k уменьшает поправку при слабой поддержке данными и высокой неопределённости, проекция запрещает уменьшение износа.

Термин «модель мира» используется в прикладном смысле. Модель по наблюдаемому состоянию процесса прогнозирует следующий переход износа и дополнительно возвращает величины, нужные для принятия решения: неопределённость прогноза, степень поддержки обучающими данными и риск большой ошибки. Такое понимание близко к архитектурам совместного предсказывающего вложения (JERA) [2], [3], в которых прогноз строится в пространстве представлений, а не сырых наблюдений. В настоящей работе этот принцип применяется к построению модели перехода, а не к обучению представлений.

Вклад работы состоит в следующем. Во-первых, предложена модель PRISM-MPWM для диагностики перехода износа при фрезеровании. Во-вторых, сформулирована ограниченная остаточная поправка к базовой модели по силам и моментам с взвешиванием доверия. В-третьих, помимо RMSE и средней абсолютной ошибки (MAE) исследованы устойчивость по инструментам, ошибка в зоне высокого износа, недооценка высокого износа, монотонность прогноза,

калибровка интервалов, прогноз с отказом и перестановочные контроли. В-четвёртых, задача диагностики наблюдаемого перехода явно отделена от задачи выбора будущего режима резания.

II. СВЯЗАННЫЕ РАБОТЫ

Открытый набор данных Denkena, Klemme и Stiehl содержит многомерные временные ряды фрезерования на трёх станках девятью концевыми фрезами: силы, измеренные динамометром, сигналы системы ЧПУ и ширину площадки износа по задней поверхности VB [1]. Набор подходит для диагностики состояния инструмента, но сам по себе не позволяет проверить выбор будущего режима резания.

Работа I-JERA показала, что самообучение можно строить на предсказании в пространстве представлений, не восстанавливая сырые наблюдения [2]. В V-JERA 2 этот принцип распространён на видео и задачи планирования [3]. Метод TD-MPC2 использует латентную модель мира для управления с прогнозирующей моделью [4]. Из этих работ заимствуется общий принцип: будущий переход прогнозируется в компактном описании состояния, а модель динамики отделена от оценки доверия к ней.

В задачах механообработки важны гибридные модели, учитывающие физическую структуру процесса. Примером служит физически направленная нейронная модель износа инструмента [5]. Настоящая работа следует той же логике, но обучаемый блок в ней остаточный: он не заменяет базовую модель, а уточняет её прогноз в ограниченных пределах. Отказ от прогноза при слабой поддержке данными основан на выборочной регрессии с конформной калибровкой [6] и используется как средство диагностики, а не как гарантия безопасности.

III. ДАННЫЕ И ПОСТАНОВКА ЗАДАЧИ

Целевой величиной служит износ по задней поверхности VB в миллиметрах. Для каждого перехода между соседними записями одного инструмента используются агрегированные признаки сигналов, текущий износ VB_k , прогноз базовой модели по силам и моментам, а также оценки поддержки данными и неопределённости. Обучающая выборка содержит 1024 перехода со станков 1 и 2, тестовая выборка содержит 1766 переходов станка 3, исключённого из обучения и настройки.

Такое разбиение проверяет перенос модели на другой станок, а не качество интерполяции между соседними переходами одного процесса. Набор не содержит для каждого перехода будущего режима резания $a_k = [V_c, f_z, a_p, a_e, \text{СОЖ}]$, где V_c обозначает скорость резания, f_z подачу на зуб, a_p и a_e глубину и ширину фрезерования, а СОЖ указывает на подачу смазочно-охлаждающей жидкости. Поэтому результат относится к диагностике перехода износа по наблюдаемым сигналам, а не к выбору режима резания.

Малые значения ошибки требуют пояснения. Ошибка порядка десятых долей микрометра не означает, что с такой точностью прогнозируется весь срок службы

инструмента. Оценивается одношаговый переход при известном текущем износе VB_k . На тестовой выборке средний износ равен 0,0835 мм, а средний прирост за один переход равен 0,236 мкм. Для PRISM-MPWM RMSE составляет 0,445 мкм, MAE составляет 0,268 мкм.

IV. МЕТОД

Обозначим через $\widehat{VB}_{k+1}^T$ прогноз базовой модели по силам и моментам. Обучаемый блок не предсказывает износ целиком, а получает в качестве целевой величины остаток

$$r_k = VB_{k+1} - \widehat{VB}_{k+1}^T. \quad (1)$$

Остаток предсказывается градиентным бустингом над деревьями решений по признакам перехода, из которых исключены номера станка и инструмента. Итоговый прогноз вычисляется по формуле

$$\widehat{VB}_{k+1} = \Pi_{\mathcal{X}} \left[\widehat{VB}_{k+1}^T + g_k D_r \tanh \left(\frac{\mu_k}{D_r} \right) \right], \quad (2)$$

где μ_k обозначает предсказанный остаток, D_r задаёт наибольшую допустимую поправку, g_k является весом доверия к поправке, а $\Pi_{\mathcal{X}}$ обозначает проекцию на множество физически допустимых значений. В данной работе проекция запрещает уменьшение накопленного износа:

$$\widehat{VB}_{k+1} \geq VB_k. \quad (3)$$

Вес доверия зависит от поддержки данными и неопределённости:

$$g_k = \sigma(b + \alpha_S S_k - \alpha_U U_k + \alpha_C C_k), \quad (4)$$

где σ обозначает логистическую функцию, S_k оценивает, насколько переход похож на обучающие примеры, U_k оценивает неопределённость прогноза, C_k выражает уверенность в поправке и убывает с ростом U_k , а b , α_S , α_U , α_C являются настраиваемыми коэффициентами. Если похожих переходов в обучающей выборке мало или неопределённость высока, вес поправки уменьшается, и прогноз приближается к прогнозу базовой модели. Тем самым базовая модель защищена от статистической коррекции вне области применимости поправки.

Итоговый вариант модели дополнительно учитывает сглаженное смещение предыдущих остатков того же инструмента. Его настройки выбраны по устойчивости на калибровочной части станков 1 и 2: по разбросу улучшения при бутстрэпе по инструментам и по ухудшению при исключении одного инструмента.

V. ПРОТОКОЛ ЭКСПЕРИМЕНТА

Все параметры модели, правила калибровки и критерии отбора зафиксированы до итоговой оценки на станке 3. Базовой моделью служит линейная регрессия с гребневой (ridge) регуляризацией, прогнозирующая прирост износа за переход. Сначала прирост грубо оценивается линейной функцией текущего износа VB_k , затем гребневая регрессия уточняет его по стандартизованным признакам: текущему износу, накопленному времени контакта и времени контакта за переход, среднеквадратичному значению, разбросу и

логарифму энергии сигналов силы резания и крутящего момента, а также по индикаторам номера инструмента (инструменты станка 3 в обучении не встречаются, поэтому на нём эти индикаторы информации не несут). Прогноз износа равен VB_k плюс неотрицательный прирост. Далее она называется базовой моделью по силам и моментам. Она уже даёт сильный диагностический прогноз, поэтому сравнение с ней строже, чем сравнение с многослойным перцептроном, обученным без признаков сил и моментов.

Оценка включает RMSE и MAE, групповой бутстрэп по инструментам, ошибку на худшем инструменте, ошибку в зоне высокого износа, штраф за недооценку высокого износа, долю нарушений монотонности, покрытие интервалов и прогноз с отказом. Перестановочные контроли проверяют, что улучшение не объясняется подгонкой к случайной особенности разметки: в первом контроле остатки обучающей выборки случайно переставлены, во втором сдвинуты во времени внутри каждого инструмента. Дополнительные проверки выполнены для варианта с ограниченной поправкой, итоговый отбор по устойчивости меняет его RMSE с 0,447 до 0,445 мкм.

VI. РЕЗУЛЬТАТЫ

Основной результат приведён в таблице I. PRISM-MPWM снижает RMSE одношагового прогноза с 0,486 до 0,445 мкм, то есть на 8,45 % относительно базовой модели по силам и моментам (рис. 2).

ТАБЛИЦА I
Одношаговый прогноз износа на станке 3, исключённом из обучения

Модель	RMSE, мм	RMSE, мкм	Изменение
Базовая модель по силам и моментам	$4,8620 \cdot 10^{-4}$	0,486	0
Остаточная модель без номеров станка и инструмента	$4,6907 \cdot 10^{-4}$	0,469	-3,52 %
Ограниченная поправка	$4,4737 \cdot 10^{-4}$	0,447	-7,99 %
PRISM-MPWM, отбор по устойчивости	$4,4513 \cdot 10^{-4}$	0,445	-8,45 %




Рис. 2. PRISM-MPWM снижает ошибку одношагового прогноза износа на станке 3, исключённом из обучения. Показаны базовая модель по силам и моментам и варианты остаточной поправки; итоговая модель PRISM-MPWM получена отбором по устойчивости.

Групповой бутстрэп по инструментам даёт для разности RMSE 95 %-интервал от -0,049 до -0,015 мкм (рис. 3, а). Интервал целиком лежит в области улучшения, поэтому выигрыш не объясняется удачным результатом на одном инструменте. Ошибка на худшем инструменте также снижается: 0,454 мкм у PRISM-MPWM против 0,504 мкм у базовой модели (рис. 3, б).




Рис. 3. Улучшение устойчиво по инструментам. а) 95 %-интервал группового бутстрэпа по инструментам для разности RMSE варианта с ограниченной поправкой и базовой модели; б) средняя RMSE и RMSE худшего инструмента. Точка «лучший по тесту» получена отбором по тестовой выборке, приведена только для справки и не входит в заявляемый результат.

Зона высокого износа важна для практики, поскольку недооценка износа в ней опаснее обычной ошибки. В зоне VB не менее 106 мкм PRISM-MPWM снижает RMSE с 0,543 до 0,483 мкм, а штраф за недооценку уменьшается с $5,816 \cdot 10^{-7}$ до $3,62 \cdot 10^{-7}$ мм² (рис. 4, б и в). Нарушений монотонности прогноза на тестовой выборке нет.




Рис. 4. Преимущество PRISM-MPWM сохраняется на нескольких шагах и в зоне высокого износа и исчезает при перестановке остатков. а) RMSE многошагового прогноза на записанных данных; б) RMSE при

VB не менее 106 мкм; в) штраф за недооценку высокого износа; г) RMSE при обучении на исходных (Исх.), случайно переставленных (Перест.) и сдвинутых во времени (Сдвиг) остатках.

Многошаговый прогноз на записанных данных показывает, сохраняется ли польза поправки за пределами одного перехода. Для этого одношаговые приращения прогноза суммируются вдоль нескольких переходов начиная с измеренного VB_k . На горизонтах 1, 2, 3 и 5 переходов PRISM-MPWM точнее базовой модели, разность RMSE равна соответственно $-0,039$, $-0,106$, $-0,188$ и $-0,366$ мкм (табл. II, рис. 4, а). Эта проверка выполнена на уже наблюденных переходах и не является проверкой планирования режимов.

ТАБЛИЦА II
Многошаговый прогноз на станке 3, RMSE в мкм

Горизонт, переходов	1	2	3	5
Базовая модель	0,486	0,716	0,935	1,343
PRISM-MPWM	0,447	0,610	0,746	0,977
Разность	$-0,039$	$-0,106$	$-0,188$	$-0,366$

Перестановочные контроли подтверждают, что поправка использует содержание остатка. При обучении на случайно переставленных остатках RMSE возрастает до 0,493 мкм, то есть становится выше, чем у базовой модели, а при сдвиге остатков во времени составляет 0,457 мкм против 0,447 мкм на исходных остатках (рис. 4, г).

Калибровка интервалов и прогноз с отказом служат средствами оценки доверия. До калибровки фактическое покрытие номинальных 90- и 95-процентных интервалов на станке 3 составляло 0,858 и 0,869. После конформной калибровки на данных станков 1 и 2 оно возросло до 0,889 и 0,928 (рис. 5, а).

При отказе от прогноза на переходах с наименьшей поддержкой обучающими данными ошибка принятых прогнозов убывает и при любой доле принятых переходов остаётся ниже ошибки базовой модели на тех же переходах (рис. 5, б). Если принимать прогноз для 95 % переходов, RMSE принятых прогнозов равна 0,369 мкм против 0,402 мкм у базовой модели, а средняя абсолютная ошибка на отклонённых переходах примерно в 3,04 раза выше, чем на принятых. Такой механизм полезен для передачи трудных случаев оператору, но не является доказательством безопасности автоматического управления.




Рис. 5. Калибровка приближает покрытие интервалов к номинальному, а отказ на переходах со слабой поддержкой данными снижает ошибку принятых прогнозов. а) фактическое покрытие 90- и 95-процентных интервалов до и после конформной калибровки, штриховые линии показывают номинальный уровень; б) RMSE принятых прогнозов в

зависимости от доли принятых переходов, пунктир отмечает долю 95 %.

VII. ОБСУЖДЕНИЕ

Полученные результаты подтверждают основное положение работы: при прогнозировании износа инструмента эффективнее обучать поправку к сильной базовой модели по силам и моментам, чем строить прогноз VB заново. Базовая модель обеспечивает основной прогноз, а обучаемая часть добавляет ограниченную поправку только там, где поддержка данными и неопределённость позволяют ей доверять.

Название «модель мира» не означает, что система управляет станком. Оно означает, что модель описывает переход состояния процесса и возвращает величины, необходимые для принятия решения: прогноз, неопределённость, поддержку данными, риск большой ошибки и признак отказа от автоматической выдачи прогноза. Для перехода к модели, прогнозирующей износ в зависимости от выбранного режима, нужны записи проходов с известными V_c , f_z , a_p , a_e и измеренным изменением VB.

VIII. ОГРАНИЧЕНИЯ

Во-первых, проверка выполнена на открытом наборе данных со станком, исключённым из обучения, и не заменяет промышленной проверки на новом оборудовании. Во-вторых, силы и моменты являются сигналами, наблюдаемыми во время прохода; без отдельной модели сил их нельзя считать заранее известными при планировании режима. В-третьих, калибровка улучшает интервалы прогноза, но не гарантирует безопасность. В-четвёртых, синтетические данные допустимо использовать только для предварительного обучения и проверок устойчивости, но не как самостоятельное подтверждение точности прогноза.

IX. ЗАКЛЮЧЕНИЕ

Предложенная модель PRISM-MPWM представляет прогноз износа инструмента как физически обоснованную остаточную модель перехода состояния процесса. На станке 3 открытого набора данных, исключённом из обучения, она снижает RMSE одношагового прогноза с 0,486 до 0,445 мкм и улучшает показатели риска. Результат подтверждён групповым бутстрэпом, ошибкой в зоне высокого износа, многошаговым прогнозом, проверкой монотонности и перестановочными контролями.

В текущем виде модель является средством диагностики перехода износа. Дальнейшая проверка требует записей с полным описанием режима резания на каждом проходе и испытаний на новых инструментах и станках.

ДОСТУПНОСТЬ ДАННЫХ

Исходный набор данных является открытым и описан в работе [1]. Результаты статьи получены воспроизводимыми программами и сохранены в виде таблиц и векторных рисунков. Авторы заявляют об

отсутствии конфликта интересов.

БИБЛИОГРАФИЯ

- [1] B. Denkena, H. Klemme, and T. H. Stiehl, "Multivariate time series data of milling processes with varying tool wear and machine tools," *Data in Brief*, vol. 50, Art. no. 109574, 2023, doi: 10.1016/j.dib.2023.109574. [Online]. Available: <https://doi.org/10.1016/j.dib.2023.109574>
- [2] M. Assran, Q. Duval, I. Misra, P. Bojanowski, P. Vincent, M. Rabbat, Y. LeCun, and N. Ballas, "Self-supervised learning from images with a joint-embedding predictive architecture," in *Proc. IEEE/CVF Conf. Computer Vision and Pattern Recognition (CVPR)*, 2023, pp. 15619–15629. [Online]. Available: <https://arxiv.org/abs/2301.08243>
- [3] M. Assran *et al.*, "V-JEPA 2: Self-supervised video models enable understanding, prediction and planning," arXiv:2506.09985, 2025. [Online]. Available: <https://arxiv.org/abs/2506.09985>
- [4] N. Hansen, H. Su, and X. Wang, "TD-MPC2: Scalable, robust world models for continuous control," in *Proc. Int. Conf. Learning Representations (ICLR)*, 2024. [Online]. Available: <https://arxiv.org/abs/2310.16828>
- [5] J. Wang, Y. Li, R. Zhao, and R. X. Gao, "Physics guided neural network for machining tool wear prediction," *J. Manuf. Syst.*, vol. 57, pp. 298–310, 2020, doi: 10.1016/j.jmsy.2020.09.005. [Online]. Available: <https://doi.org/10.1016/j.jmsy.2020.09.005>
- [6] A. Sokol, N. Moniz, and N. Chawla, "Conformalized selective regression," arXiv:2402.16300, 2024. [Online]. Available: <https://arxiv.org/abs/2402.16300>

PRISM-MPWM: a process world model for milling tool-wear diagnostics

A.A. Lobko

Abstract—This paper presents PRISM-MPWM (Physics-Residual Invariant Support-aware Machine Process World Model), a diagnostic process model for estimating the flank wear (VB) of an end mill. The model does not predict wear from scratch. It refines the prediction of a baseline force and torque model: a trained block predicts only the residual error of that baseline, the size of the correction is bounded, and its weight decreases when the transition is poorly supported by training data or the predictive uncertainty is high. A physical constraint forbids a decrease of accumulated wear. The model is evaluated on the public Denkena, Klemme and Stiehl milling dataset: training and tuning use machines 1 and 2, and machine 3 is reserved for the final evaluation. PRISM-MPWM reduces the one-step root-mean-square error of wear prediction from 0.486 to 0.445 μm , an 8.45% improvement over the baseline. The result is supported by a grouped bootstrap over tools, lower error in the high-wear zone, a smaller underprediction of high wear, zero monotonicity violations, prediction with abstention on difficult transitions and permutation controls. The result concerns wear diagnostics from observed signals and does not extend to cutting parameter selection.

Keywords—digital twin, milling, process world model, residual model, tool wear, uncertainty.

REFERENCES

- [1]B. Denkena, H. Klemme, and T. H. Stiehl, “Multivariate time series data of milling processes with varying tool wear and machine tools,” *Data in Brief*, vol. 50, Art. no. 109574, 2023, doi: 10.1016/j.dib.2023.109574. [Online]. Available: <https://doi.org/10.1016/j.dib.2023.109574>
- [2]M. Assran, Q. Duval, I. Misra, P. Bojanowski, P. Vincent, M. Rabbat, Y. LeCun, and N. Ballas, “Self-supervised learning from images with a joint-embedding predictive architecture,” in *Proc. IEEE/CVF Conf. Computer Vision and Pattern Recognition (CVPR)*, 2023, pp. 15619–15629. [Online]. Available: <https://arxiv.org/abs/2301.08243>
- [3]M. Assran et al., “V-JEPA 2: Self-supervised video models enable understanding, prediction and planning,” *arXiv:2506.09985*, 2025. [Online]. Available: <https://arxiv.org/abs/2506.09985>
- [4]N. Hansen, H. Su, and X. Wang, “TD-MPC2: Scalable, robust world models for continuous control,” in *Proc. Int. Conf. Learning Representations (ICLR)*, 2024. [Online]. Available: <https://arxiv.org/abs/2310.16828>
- [5]J. Wang, Y. Li, R. Zhao, and R. X. Gao, “Physics guided neural network for machining tool wear prediction,” *J. Manuf. Syst.*, vol. 57, pp. 298–310, 2020, doi: 10.1016/j.jmsy.2020.09.005. [Online]. Available: <https://doi.org/10.1016/j.jmsy.2020.09.005>
- [6]A. Sokol, N. Moniz, and N. Chawla, “Conformalized selective regression,” *arXiv:2402.16300*, 2024. [Online]. Available: <https://arxiv.org/abs/2402.16300>