

EKSPLORASI MODEL *PREDICTIVE MAINTENANCE* UNTUK PREDIKSI KEAUSAN PAHAT PADA PROSES *MILLING* MENGGUNAKAN *MACHINE LEARNING* (STUDI KASUS: DATASET NASA)

*Akmal Fathurohman Pratama¹, Toni Prahasto²

¹Mahasiswa Jurusan Teknik Mesin, Fakultas Teknik, Universitas Diponegoro

²Dosen Jurusan Teknik Mesin, Fakultas Teknik, Universitas Diponegoro

Jl. Prof. Sudharto, SH., Tembalang-Semarang 50275, Telp. +62247460059

*E-mail: akmalfathurohmanp@gmail.com

Abstrak

Industri 4.0 mendorong integrasi sistem digital untuk mengurangi kegagalan produksi yang tidak terduga, di mana keausan pahat (*tool wear*) menjadi tantangan signifikan karena sulit diprediksi secara *real-time*. Penelitian ini bertujuan mengeksplorasi model prediksi keausan pahat menggunakan *machine learning* berbasis dataset NASA Milling guna mendukung strategi *predictive maintenance*. Metodologi meliputi akuisisi data, *preprocessing*, dan *feature engineering* untuk mengekstraksi indikator fisik seperti *wear rate*, *total vibration*, *total acoustic emission*, dan *cutting intensity*. Hasil penelitian menunjukkan bahwa *Logistic Regression* adalah model terbaik dengan akurasi 76,5% dan nilai *recall* mencapai 93,3%. Tingginya *recall* membuktikan keandalan model dalam meminimalkan risiko *false negative* yang berpotensi merusak benda kerja. Penelitian menyimpulkan bahwa melalui *feature engineering* yang tepat, model linear sederhana mampu memberikan prediksi yang lebih stabil dibandingkan model kompleks pada dataset industri yang terbatas.

Kata kunci: dataset nasa; *feature engineering*; *machine learning*; *milling*; *predictive maintenance*

Abstract

Industry 4.0 encourages the integration of digital systems to reduce unexpected production failures, where tool wear poses a significant challenge due to its difficulty in real-time prediction. This study aims to explore a tool wear prediction model using machine learning based on the NASA Milling dataset to support predictive maintenance strategies. The methodology includes data acquisition, preprocessing, and feature engineering to extract physical indicators such as wear rate, total vibration, total acoustic emission, and cutting intensity. The results showed that Logistic Regression was the best model with an accuracy of 76.5% and a recall value of 93.3%. The high recall demonstrates the model's reliability in minimizing the risk of false negatives that could potentially damage the workpiece. The study concluded that, through appropriate feature engineering, a simple linear model can provide more stable predictions than a complex model on a limited industrial dataset.

Keywords : *feature engineering*; *machine learning*; *milling*; *nasa dataset*; *predictive maintenance*

1. Pendahuluan

Perkembangan Industri 4.0 saat ini menitikberatkan pada integrasi antara sistem fisik dan digital melalui teknologi sensor cerdas, akuisisi sinyal, dan kecerdasan buatan (AI) untuk menghindari kegagalan produksi yang tidak terduga [1]. Dalam proses manufaktur, *milling* memegang peranan krusial untuk pembentukan komponen presisi tinggi, namun sering terhambat oleh masalah keausan pahat (*tool wear*) [2].


Keausan pahat secara langsung menurunkan kualitas permukaan, akurasi dimensi, dan dalam kasus ekstrem dapat menyebabkan kerusakan mesin serta kecelakaan kerja [2]. Secara tradisional, operator menentukan waktu penggantian pahat berdasarkan pengalaman subjektif seperti suara atau warna geram, yang sering kali tidak konsisten dan tidak akurat [3]. *Machine learning* menawarkan solusi dengan kemampuan mempelajari pola non-linear dari data sensor secara otomatis [2].

Meskipun pemantauan berbasis data mulai berkembang, banyak penelitian terdahulu terjebak pada algoritma *deep learning* yang sangat kompleks yang berisiko mengalami *overfitting* jika diterapkan pada dataset industri berskala kecil [2]. Penelitian ini mengeksplorasi efektivitas pendekatan *feature engineering* untuk mentransformasi sinyal mentah menjadi fitur fisik yang bermakna, serta membandingkan performa model *Logistic Regression*, SVM, dan *Random Forest* menggunakan dataset standar industri dari NASA Ames Prognostics Data Repository [4].

2. Metode Penelitian

2.1 Dataset NASA Milling

Penelitian ini menggunakan NASA Milling Dataset yang merekam proses pemesinan secara *run-to-failure* [1]. Data dikumpulkan melalui pemantauan tidak langsung (*indirect monitoring*) menggunakan sensor getaran, emisi akustik (*acoustic emission*), dan arus *spindle* (*spindle motor current*) [2]. Penempatan sensor dilakukan pada meja mesin dan spindle untuk menangkap dinamika proses secara holistik [5].




Gambar 1. Penempatan Sensor oleh NASA [6]

2.2 Pipeline Pengolahan Data

Proses dimulai dari akuisisi data mentah, diikuti oleh pembersihan data (*cleaning*) untuk menangani *missing values* dan *noise* [7]. Data kemudian ditransformasikan ke dalam satuan teknis standar (mm, s, V) untuk menjaga konsistensi analisis [5].

Selain itu, verifikasi terhadap ambang batas (*threshold*) sinyal juga dilakukan untuk memastikan bahwa tidak ada anomali data yang lolos ke tahap komputasi selanjutnya.

Guna memberikan representasi visual yang komprehensif mengenai bagaimana data mentah diproses hingga siap dianalisis, seluruh rangkaian sistematis dan kronologi konversi data tersebut dirangkum secara skematis ke dalam sebuah *pipeline* pengolahan data yang disajikan pada Gambar 2.



Gambar 2. Pipeline Pengolahan Data

2.3 Feature Engineering

Tahap ini krusial untuk menjembatani data sensor yang kompleks dengan kebutuhan arsitektur model [4]. Fitur hasil rekayasa yang dikembangkan mencakup ekstraksi statistik di domain waktu dan frekuensi seperti:

1. *Wear Rate*: Laju keausan kumulatif terhadap waktu [8].
2. *Total Vibration*: Integrasi sinyal getaran meja dan spindel melalui nilai RMS atau puncak sinyal [5].
3. *Total Acoustic Emission*: Kombinasi sinyal AE untuk menangkap fenomena mikro seperti retakan material [2].
4. *Cutting Intensity*: Interaksi antara parameter pemotongan seperti *depth of cut* dan *feed rate* [5].

2.4 Label Klasifikasi dan Pemodelan

Kondisi pahat dikategorikan berdasarkan standar ISO 3685 dengan ambang batas keausan tepi pahat (*flank wear* / VB) [9]. sehingga diperoleh dua label klasifikasi, yaitu:


- A. Label 0 (Normal): VB < 0,3 mm [10].
- B. Label 1 (Aus): VB ≥ 0,3 mm [10].

Tiga algoritma yang dievaluasi adalah *Random Forest* yang menggunakan integrasi beberapa pohon keputusan, *Support Vector Machine* yang mencari *hyperplane* optimal di ruang dimensi tinggi, dan *Logistic Regression* sebagai model linear *baseline* [11].

3 Hasil dan Pembahasan


3.1 Exploratory Data Analysis (EDA)

Analisis statistik menunjukkan korelasi positif (0,36) antara keausan pahat dan waktu pemesinan, mengonfirmasi teori *cumulative damage*, di mana akumulasi kerusakan bertambah seiring bertambahnya waktu operasi [8]. *Heatmap* korelasi juga membuktikan bahwa fitur hasil rekayasa seperti *total vibration* memiliki korelasi sangat kuat (0,79) dengan sinyal basisnya, yang memvalidasi bahwa informasi utama tidak hilang selama integrasi sinyal untuk penyederhanaan model [4].



Gambar 3. Correlation Heatmap

Distribusi data menunjukkan pola progresif non-linear di mana laju keausan meningkat tajam saat memasuki fase *accelerated wear* (fase keausan cepat) sebelum terjadi kegagalan total [2].



Gambar 4. Tool Wear vs Machining Time

3.2 Perbandingan Performa Model

Berdasarkan hasil pengujian, diperoleh perbandingan metrik dari *Random Forest*, *Logistic Regression*, dan *Support Vector Machine* yang dapat dilihat pada Tabel 1 berikut.

Tabel 1. Perbandingan Performa Model


Metrik	<i>Random Forest</i>	<i>Logistic Regression</i>	<i>Support Vector Machine</i>
<i>Accuracy</i>	73,52%	76,5%	70,6%
<i>Precision</i>	66,66%	66,7%	60,9%
<i>Recall</i>	80%	93,3%	93,3%
<i>F1-Score</i>	0,727	0,778	0,737

Logistic Regression ditetapkan sebagai model terbaik karena stabilitasnya pada dataset industri yang terbatas, sehingga mampu menghindari risiko *overfitting* yang sering dialami oleh model kompleks seperti *Random Forest* ketika jumlah sampel data tidak mencukupi untuk proses *training* yang luas [4]. Model linier terbukti lebih tangguh untuk mengekstrak informasi non-redundan dari dataset skala kecil dibandingkan model *ensemble* atau *deep learning* yang membutuhkan data besar agar optimal [4].

3.3 Analisis Confusion Matrix dan Feature Importance


Model terbaik (*Logistic Regression*) hanya menghasilkan satu kesalahan *false negative* (pahat aus yang tidak terdeteksi) [12]. Dalam konteks *predictive maintenance*, ini sangat krusial karena kegagalan mendeteksi keausan kritis (Tipe II *error*) jauh lebih berbahaya dan mahal dampaknya terhadap kerusakan mesin, daripada kesalahan penggantian pahat yang terlalu dini (Tipe I *error* / *false positive*) [12].

Ketidakmampuan mendeteksi keausan pahat secara tepat waktu berpotensi memicu kegagalan katastrofik pada komponen mesin dan menurunkan kualitas dimensi benda kerja. Untuk melihat distribusi klasifikasi serta visualisasi performa model ini secara mendetail, hasil pemetaan dari pengujian aktual dan prediksi tersebut disajikan melalui *Confusion Matrix* pada Gambar 5.



Gambar 5 Confusion Matrix Logistic Regression

Analisis *Feature Importance* menempatkan *machining time* sebagai fitur paling dominan, diikuti oleh *material type* dan *acoustic emission spindle* [11]. Hal ini menegaskan bahwa waktu pemesinan (*machining time*) adalah faktor akumulatif utama degradasi pahat, sementara tipe material dan emisi akustik spindle memberikan indikasi signifikan terhadap karakteristik benda kerja serta kondisi dinamis pada zona pemotongan [2].



Gambar 6. *Feature Importance*

3.4 Implikasi Praktis

Model yang dikembangkan diintegrasikan ke dalam sebuah *Early Warning System* (Sistem Peringatan Dini) yang mampu memicu peringatan visual otomatis saat pahat mendekati ambang batas kritis 0,3 mm sesuai standar ISO 3685 [2]. Implementasi sistem pemantauan ini berpotensi mengurangi *downtime* mesin hingga sekitar 20% dan meningkatkan efisiensi biaya penggantian pahat, yang secara keseluruhan berkontribusi pada penghematan biaya manufaktur global antara 3% hingga 12% [2].

4. Kesimpulan

Penelitian ini menganalisis performa sistem pemantauan kondisi pahat (*tool condition monitoring*) pada proses *milling* melalui parameter keausan tepi pahat (*flank wear* / VB), sinyal getaran, dan emisi akustik menggunakan berbagai algoritma *machine learning*. Berikut kesimpulan dari penelitian ini:

1. Laju keausan pahat (VB) meningkat secara progresif dan non-linear seiring bertambahnya waktu pemesinan, di mana akumulasi kerusakan bertambah hingga memasuki fase *accelerated wear* sebelum terjadi kegagalan total.
2. Model *Logistic Regression* memberikan performa terbaik (akurasi 76,5%) dibandingkan model kompleks seperti *Random Forest* atau *Support Vector Machine* karena stabilitasnya pada dataset industri yang terbatas, sehingga mampu secara efektif menghindari risiko *overfitting*.
3. Nilai fitur hasil rekayasa seperti total getaran dan emisi akustik ditemukan relatif stabil dalam memberikan indikasi kondisi dinamis zona pemotongan, sementara *machining time* menjadi fitur yang paling berkorelasi kuat dengan degradasi pahat secara kumulatif.
4. Secara keseluruhan, implementasi model ini ke dalam sistem peringatan dini (*Early Warning System*) berpotensi mengurangi *downtime* mesin hingga 20% dan menghemat biaya manufaktur antara 3% hingga 12% melalui optimasi penggantian pahat yang tepat waktu.

5. Daftar Pustaka

- [1] Z. M. Çınar, A. A. Nuhu, Q. Zeeshan, and O. Korhan, "Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0," *Sustainability*, vol. 12, no. 19, pp. 1–42, 2020.
- [2] F. Pashmforoush, A. Ebrahimi Araghizad, and E. Budak, "Tool wear prediction in milling process using physics-informed machine learning and thermo-mechanical force model with monitoring applications," *J. Manuf. Syst.*, vol. 82, no. February, pp. 1192–1212, 2025, doi: 10.1016/j.jmsy.2025.08.014.
- [3] Z. He, T. Shi, J. Xuan, and T. Li, "Research on tool wear prediction based on temperature signals and deep learning,"

-
- [4] *Wear*, vol. 478–479, no. March, p. 203902, 2021, doi: 10.1016/j.wear.2021.203902.
 - [5] A. Fertig, M. Weigold, and Y. Chen, “Machine Learning based quality prediction for milling processes using internal machine tool data,” *Adv. Ind. Manuf. Eng.*, vol. 4, no. March, p. 100074, 2022, doi: 10.1016/j.aime.2022.100074.
 - [6] R. Munaro, A. Attanasio, and A. Del Prete, “Tool Wear Monitoring with Artificial Intelligence Methods: A Review,” *J. Manuf. Mater. Process.*, vol. 7, no. 4, 2023, doi: 10.3390/jmmp7040129.
 - [7] K. Goebel and A. Agogino, “Documentation for Mill Data Set,” *NASA Progn. Data Repos. NASA Ames Res. Cent.*, pp. 1–10, 2007, [Online]. Available: <https://www.nasa.gov/content/prognostics-center-of-excellence-data-set-repository>.
 - [8] K. Danach, H. Harb, H. Issa, and L. Saker, “An explainable data-driven optimization framework for industrial predictive maintenance scheduling,” *Results Eng.*, vol. 29, no. October 2025, p. 109022, 2026, doi: 10.1016/j.rineng.2026.109022.
 - [9] H. Chen, J. Yang, Q. Qi, and H. Ding, “A robotic grinding parameter optimization approach considering tool wear to guarantee material removal accuracy and surface quality,” *J. Manuf. Process.*, vol. 159, no. December 2025, pp. 228–242, 2026, doi: 10.1016/j.jmapro.2026.01.001.
 - [10] P. Zhang *et al.*, “Tool wear monitoring and multi-step forecasting in deep hole boring based on physics-informed neural network and ARIMA model,” *Mech. Syst. Signal Process.*, vol. 249, no. February, p. 114078, 2026, doi: 10.1016/j.ymssp.2026.114078.
 - [11] G. Yin, Z. Wu, F. Jiang, J. Shen, and X. Wu, “Monitoring tool wear during turning process using surface strain sensor,” *Results Eng.*, vol. 29, no. January, 2026, doi: 10.1016/j.rineng.2026.109297.
 - [12] Q. Zhu *et al.*, “Application of machine learning in the design of biomedical nanomaterials,” *Chem. Eng. J.*, vol. 530, no. October 2025, p. 173408, 2026, doi: 10.1016/j.cej.2026.173408.
 - [13] C. He, D. Huang, R. Jia, and X. Wang, “Machine learning and insurer failure prediction,” *Int. J. Forecast.*, no. xxxx, 2026, doi: 10.1016/j.ijforecast.2025.12.004.
 - [14] R. Sharma, “How is AI For Predictive Maintenance Beneficial To Improving Manufacturing Efficiency?,” Markovate. [Online]. Available: <https://markovate.com/ai-for-predictive-maintenance/>.