



---

## Analisis Komparatif Model *Decision Tree* dan *Random Forest* untuk Pemeliharaan Prediktif Mesin *Computer Numerical Control (CNC) Milling*

Achmad Harpin Asrori<sup>1</sup>, Nanang Kurnia Wahab<sup>2</sup>

<sup>1,2</sup>Program Studi Manajemen Informatika, Fakultas Vokasi, Institut Az Zuhra

[harpin@institutazzuhra.ac.id](mailto:harpin@institutazzuhra.ac.id), [nanangkw@institutazzuhra.ac.id](mailto:nanangkw@institutazzuhra.ac.id)

### Abstrak

Pemeliharaan prediktif merupakan pendekatan penting dalam meningkatkan keandalan dan efisiensi mesin produksi, khususnya mesin *Computer Numerical Control (CNC)*, yang memiliki peran krusial dalam industri manufaktur modern. Perkembangan *machine learning* memungkinkan pemanfaatan data operasional mesin untuk memprediksi potensi kegagalan secara lebih akurat dibandingkan metode pemeliharaan konvensional. Penelitian ini bertujuan untuk melakukan analisis komparatif terhadap dua model pembelajaran mesin berbasis pohon, yaitu *Decision Tree Classifier* dan *Random Forest*, dalam mengklasifikasikan kondisi kegagalan mesin *CNC*. Penelitian ini menggunakan pendekatan klasifikasi berbasis data dengan mengindikasikan kemampuan operasional mesin, seperti temperatur udara, temperatur proses, kecepatan putar, torsi, dan keausan pahat. Dataset dibagi menjadi data pelatihan sebesar 70% dan data pengujian sebesar 30%. Evaluasi kinerja model dilakukan menggunakan beberapa metrik, antara lain *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, serta *Receiver Operating Characteristic (ROC)* dan *Area Under the Curve (AUC)*. Selain itu, diterapkan teknik *cross-validation* dan *hyperparameter tuning* untuk meningkatkan keandalan dan kemampuan generalisasi model. Hasil penelitian menunjukkan bahwa model *Random Forest* memiliki kinerja yang lebih unggul dibandingkan dengan model *Decision Tree*, dengan tingkat akurasi sebesar 0,892, sedangkan *Decision Tree* memperoleh akurasi sebesar 0,804. Nilai *AUC* yang tinggi juga mengindikasikan kemampuan *Random Forest* yang lebih baik dalam membedakan kondisi mesin normal dan gagal. Berdasarkan hasil tersebut, *Random Forest* dinilai sebagai model yang lebih efektif dan andal untuk diterapkan pada skema pemeliharaan prediktif mesin *CNC*. Temuan penelitian ini diharapkan dapat memberikan kontribusi dalam pemilihan model *machine learning* yang tepat untuk aplikasi *predictive maintenance* di lingkungan industri manufaktur.

**Kata kunci:** *Predictive Maintenance, Machine Learning, Classification, Random Forest, Decision Tree, CNC Machine.*

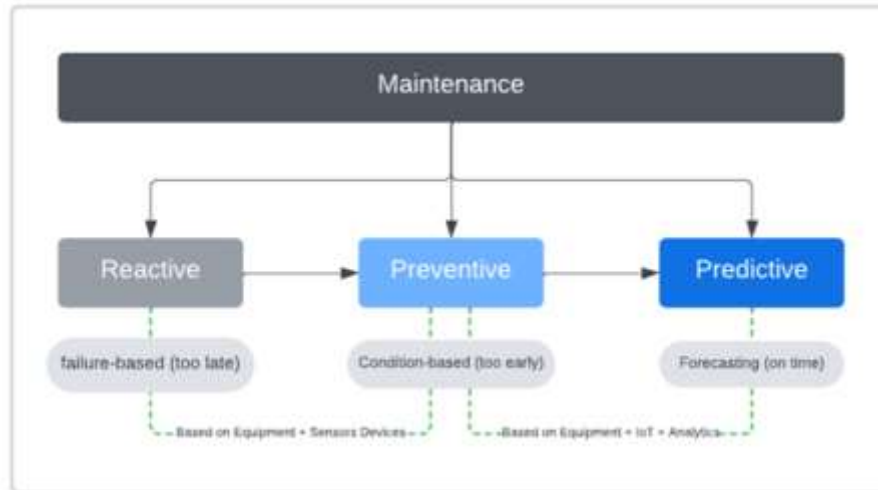
### 1. Latar Belakang

Industri manufaktur saat ini berada dalam era ekonomi digital yang ditandai dengan penerapan konsep *Industry 4.0*. *Organisation for Economic Co-operation and Development (OECD)* menyatakan bahwa setiap industri di era ekonomi digital menghadapi perkembangan pesat Teknologi Informasi dan Komunikasi (TIK) yang sekaligus menjadi peluang dan tantangan [1]. *Industry 4.0* merepresentasikan konvergensi teknologi yang menekankan otomatisasi, integrasi sistem, serta kolaborasi antara teknologi siber dan sistem fisik [2]. Dalam konteks ini, industri dituntut untuk mengadopsi pendekatan berbasis data guna meningkatkan efisiensi operasional dan daya saing global [3].

Salah satu aspek penting dalam transformasi industri manufaktur adalah pemeliharaan mesin produksi. Mesin produksi modern, khususnya *Computer Numerical Control (CNC) milling*, memegang peranan krusial dalam proses manufaktur karena kemampuannya menghasilkan komponen dengan tingkat presisi dan konsistensi yang tinggi [4]. Namun, mesin *CNC* juga rentan terhadap berbagai permasalahan operasional seperti keausan pahat (*tool wear*), fluktuasi temperatur, getaran berlebih, dan beban berlebih, yang dapat menyebabkan kegagalan mesin dan penghentian proses produksi secara tiba-tiba (*downtime*). Kondisi ini berpotensi menimbulkan kerugian finansial yang signifikan serta menurunkan efisiensi dan produktivitas industri [5].

Pendekatan pemeliharaan tradisional, seperti *reactive maintenance* dan *preventive maintenance*, dinilai belum mampu secara optimal mengantisipasi kegagalan mesin secara akurat dan tepat waktu [6]. Oleh karena itu, *predictive maintenance* muncul sebagai strategi yang lebih proaktif dengan tujuan memprediksi potensi kegagalan mesin sebelum kerusakan terjadi [7]. *Predictive maintenance* memanfaatkan data historis dan data operasional mesin untuk mengidentifikasi pola-pola yang mengindikasikan kondisi tidak normal atau potensi kerusakan [8].

Dalam beberapa tahun terakhir, pendekatan *data-driven predictive maintenance* yang didukung oleh *machine learning* telah berkembang pesat dan menunjukkan potensi yang signifikan dalam meningkatkan akurasi prediksi kegagalan mesin [9]. Algoritma *machine learning* mampu menganalisis data sensor dan parameter operasional mesin dalam jumlah besar untuk menemukan pola kompleks yang sulit diidentifikasi dengan metode konvensional [10]. Melalui proses pembelajaran dari data, model *machine learning* dapat digunakan untuk mengklasifikasikan kondisi mesin ke dalam kategori normal atau gagal, sehingga mendukung pengambilan keputusan pemeliharaan yang lebih efektif dan efisien [11].



Gambar 1. CNC Machine Tool Control System.

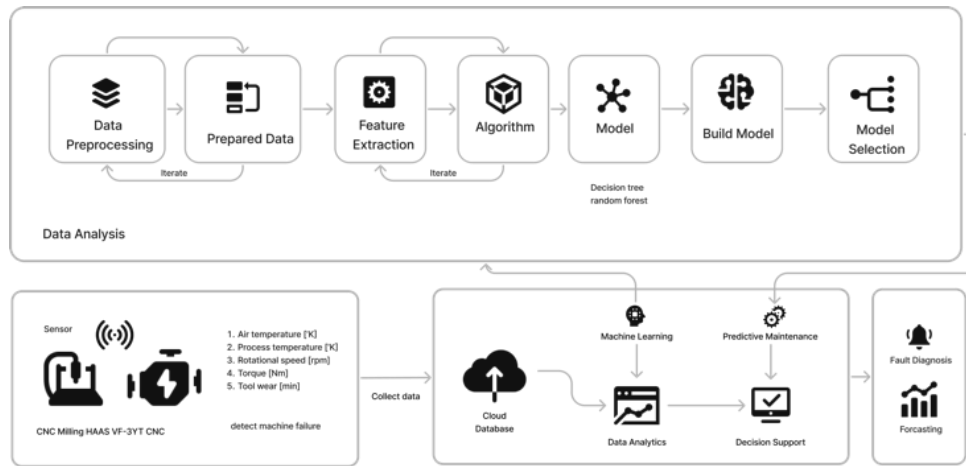
Berbagai algoritma *machine learning* telah diterapkan dalam studi *predictive maintenance*, termasuk *Decision Tree* dan *Random Forest*, yang dikenal sebagai metode klasifikasi berbasis pohon keputusan [12]. *Decision Tree* menawarkan struktur model yang sederhana dan mudah diinterpretasikan, sedangkan *Random Forest* memanfaatkan teknik *ensemble learning* untuk meningkatkan akurasi dan stabilitas prediksi [13]. Meskipun kedua algoritma tersebut banyak digunakan, masih terdapat keterbatasan studi yang secara khusus melakukan analisis komparatif yang mendalam terhadap kinerja kedua model tersebut dalam konteks *predictive maintenance* pada mesin *CNC milling* [14].

Berdasarkan permasalahan tersebut, penelitian ini berfokus pada analisis komparatif antara algoritma *Decision Tree* dan *Random Forest* dalam mengklasifikasikan kondisi kegagalan mesin *CNC milling*. Penelitian ini mengevaluasi kinerja kedua model menggunakan berbagai metrik evaluasi, seperti akurasi, *precision*, *recall*, *F1-score*, serta *ROC-AUC*, disertai dengan penerapan *cross-validation* dan *hyperparameter tuning* untuk meningkatkan reliabilitas model. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pemilihan model *machine learning* yang paling efektif untuk penerapan *predictive maintenance* pada mesin *CNC milling*, khususnya dari perspektif *data science* dan analisis prediktif.

## 2. Metode Penelitian

Kegagalan proses pemesinan pada mesin *milling* dapat disebabkan oleh berbagai faktor, seperti keausan pahat (*tool wear*), kenaikan temperatur yang berlebihan, getaran yang tidak sesuai, serta beban berlebih yang tidak diharapkan [15]. Kondisi-kondisi tersebut dapat mengganggu proses pemesinan yang seharusnya berjalan secara stabil dan konsisten. Oleh karena itu, penelitian ini menerapkan metode klasifikasi berbasis *machine learning* yang diawali dengan proses pengumpulan dataset, yaitu akuisisi data yang memuat atribut atau fitur relevan untuk kebutuhan prediksi kategori kondisi mesin.

Langkah berikutnya adalah memilih model klasifikasi yang sesuai. Beberapa algoritma yang dapat digunakan antara lain *Decision Tree* dan *Random Forest*, yang dipilih berdasarkan karakteristik data dan tujuan analisis. Setelah model ditentukan, dataset dibagi menjadi dua bagian, yaitu data pelatihan (*training data*) yang digunakan untuk membangun model, serta data pengujian (*testing data*) yang digunakan untuk mengevaluasi kinerja model yang telah dilatih.



Gambar 2. Kerangka Kerja *Predictive Maintenance CNC Milling*

Pada tahap pelatihan, model klasifikasi mempelajari pola, hubungan, atau karakteristik data berdasarkan fitur-fitur yang tersedia serta label kategorinya. Setelah model terbentuk, tahap selanjutnya adalah melakukan validasi menggunakan data pengujian. Evaluasi performa model dilakukan dengan menggunakan sejumlah metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengukur seberapa baik model dalam melakukan klasifikasi kondisi mesin. Proses optimasi model kemudian dilakukan melalui penyesuaian parameter (*hyperparameter tuning*) atau pemilihan fitur (*feature selection*) untuk meningkatkan akurasi dan kemampuan generalisasi model.

Namun demikian, perlu diperhatikan bahwa efektivitas model klasifikasi sangat dipengaruhi oleh berbagai faktor, termasuk kualitas dan kuantitas dataset, pemilihan fitur yang tepat, serta kecocokan model dengan karakteristik permasalahan. Selain itu, pemantauan dan pemeliharaan model secara berkelanjutan sangat diperlukan agar performanya tetap konsisten seiring bertambahnya data baru dan perubahan kondisi operasional.

Dengan demikian, pendekatan komprehensif yang mencakup proses pengumpulan data, pemilihan model, pelatihan, validasi, optimasi, dan pemantauan berkelanjutan merupakan elemen penting dalam keberhasilan penerapan metode klasifikasi untuk mengatasi kegagalan pemesinan pada mesin *milling*.

Tabel 1. Parameter *CNC Milling Machine*

Symbol	Parameter	Value
K	Air Temperature	Ordinal Value
K	Process Temperature	Ordinal Value
Rpm	Rotational Speed	Nominal Value
Nm	Torque	Ordinal Value
Min	Tool Wear	Nominal Value
y/n	Target	Nominal Value

Data yang digunakan dalam penelitian ini dihasilkan dari beberapa parameter yang relevan dengan proses industri pemesinan. Parameter temperatur udara (*air temperature*) dibangkitkan menggunakan proses *random walk* dan dinormalisasi dengan simpangan baku sekitar 2 K di sekitar nilai rata-rata 300 K. Selanjutnya, temperatur proses (*process temperature*) juga dibangkitkan melalui proses *random walk*, dinormalisasi dengan simpangan baku sebesar 1 K, kemudian ditambahkan sebesar 10 K terhadap nilai temperatur udara.

Parameter kecepatan putar (*rotational speed*) dihitung berdasarkan daya sebesar 2860 W dan dimodelkan menggunakan distribusi normal. Sementara itu, torsi (*torque*) dimodelkan menggunakan distribusi normal dengan nilai rata-rata sekitar 40 Nm dan simpangan baku sekitar 10 Nm, dengan batasan tidak terdapat nilai negatif. Waktu keausan pahat (*tool wear*) dihitung dengan menambahkan durasi keausan pahat yang bervariasi berdasarkan kualitas pahat (*High/Medium/Low*) terhadap pahat yang digunakan dalam proses pemesinan.

Selain parameter-parameter tersebut, dataset juga dilengkapi dengan label "*machine failure*" yang menunjukkan apakah pada suatu titik data terjadi kegagalan mesin berdasarkan mode kegagalan tertentu. Target akhir dari dataset

ini adalah melakukan klasifikasi kondisi mesin ke dalam dua kelas, yaitu gagal (*failure*) dan tidak gagal (*no failure*).

Skema pemilihan model ditentukan berdasarkan tingkat akurasi model klasifikasi serta waktu eksekusi. Selanjutnya, performa model dievaluasi dengan membandingkan nilai *precision*, *recall*, *F1-score*, dan *support*. Selain itu, evaluasi juga dilakukan menggunakan kurva *Receiver Operating Characteristic (ROC)* dan nilai *Area Under the Curve (AUC)*, serta metrik kesalahan seperti *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, dan *Mean Absolute Error (MAE)*. Nilai AUC yang mendekati 1 menunjukkan kemampuan klasifikasi model yang semakin baik, sedangkan nilai MSE, RMSE, dan MAE yang lebih kecil mengindikasikan tingkat kesalahan prediksi yang lebih rendah.

Tabel 3. AUC Classification Value

AUC Value	Status
0.9 - 1.0	Excellent
0.8 - 0.9	Very Good
0.7 - 0.8	Good
0.6 - 0.7	Satisfactory
< 0.6	Unsatisfactory/Failure

Evaluasi model klasifikasi juga mengacu pada confusion matrix, yang merepresentasikan hasil klasifikasi dalam empat kategori, yaitu *true positive*, *false positive*, *false negative*, dan *true negative*. *Confusion matrix* digunakan untuk menilai performa prediksi model berdasarkan nilai akurasi, sensitivitas, dan spesifisitas. Semakin mendekati nilai 1, semakin baik kinerja model dalam mengklasifikasikan kondisi mesin.

Tabel 2. Confusion Matrix

		Predicted	
		0	1
Actual	0	True Negative	False Positive
	1	False Negative	True Positive

Untuk memastikan keandalan dan ketahanan model terhadap variasi data, penelitian ini menerapkan teknik *cross-validation*, khususnya metode *k-fold cross-validation*. Pada metode ini, dataset dibagi menjadi k subset, di mana k-1 subset digunakan sebagai data pelatihan dan satu subset sebagai data validasi. Proses ini diulang sebanyak k kali sehingga setiap subset berperan sebagai data validasi satu kali. Kemampuan generalisasi model kemudian dievaluasi dengan merata-ratakan nilai metrik performa dari seluruh iterasi.

Selain itu, *hyperparameter tuning* dilakukan untuk mengoptimalkan parameter model, seperti kedalaman maksimum pada *Decision Tree* dan jumlah pohon pada *Random Forest*, guna meningkatkan kinerja prediktif model. Proses evaluasi, validasi, dan penyempurnaan model yang dilakukan secara iteratif ini memastikan bahwa model klasifikasi yang dihasilkan bersifat *robust*, akurat, dan mampu mengidentifikasi kegagalan mesin milling secara efektif.

### 3. Hasil dan Diskusi

Dalam solusi yang diusulkan untuk menjawab permasalahan yang dihadapi oleh industri manufaktur, analisis data dilakukan melalui beberapa tahapan utama yang saling terintegrasi. Tahapan tersebut meliputi ekstraksi fitur, transformasi fitur, pelatihan *classifier*, penerapan dan penyyetelan model, serta optimasi *classifier*. Rangkaian proses ini bertujuan untuk menghasilkan prediksi kegagalan mesin produksi secara akurat sehingga waktu pemeliharaan dapat dilakukan lebih cepat, lebih efektif, dan lebih tepat sasaran.

Untuk mendukung proses analisis tersebut, data operasional mesin dikumpulkan secara berkelanjutan dari berbagai sumber melalui mekanisme akuisisi data otomatis maupun manual. Data yang telah dikumpulkan kemudian disimpan dalam basis data dan digunakan sebagai masukan bagi proses analisis dan pemantauan kondisi mesin.

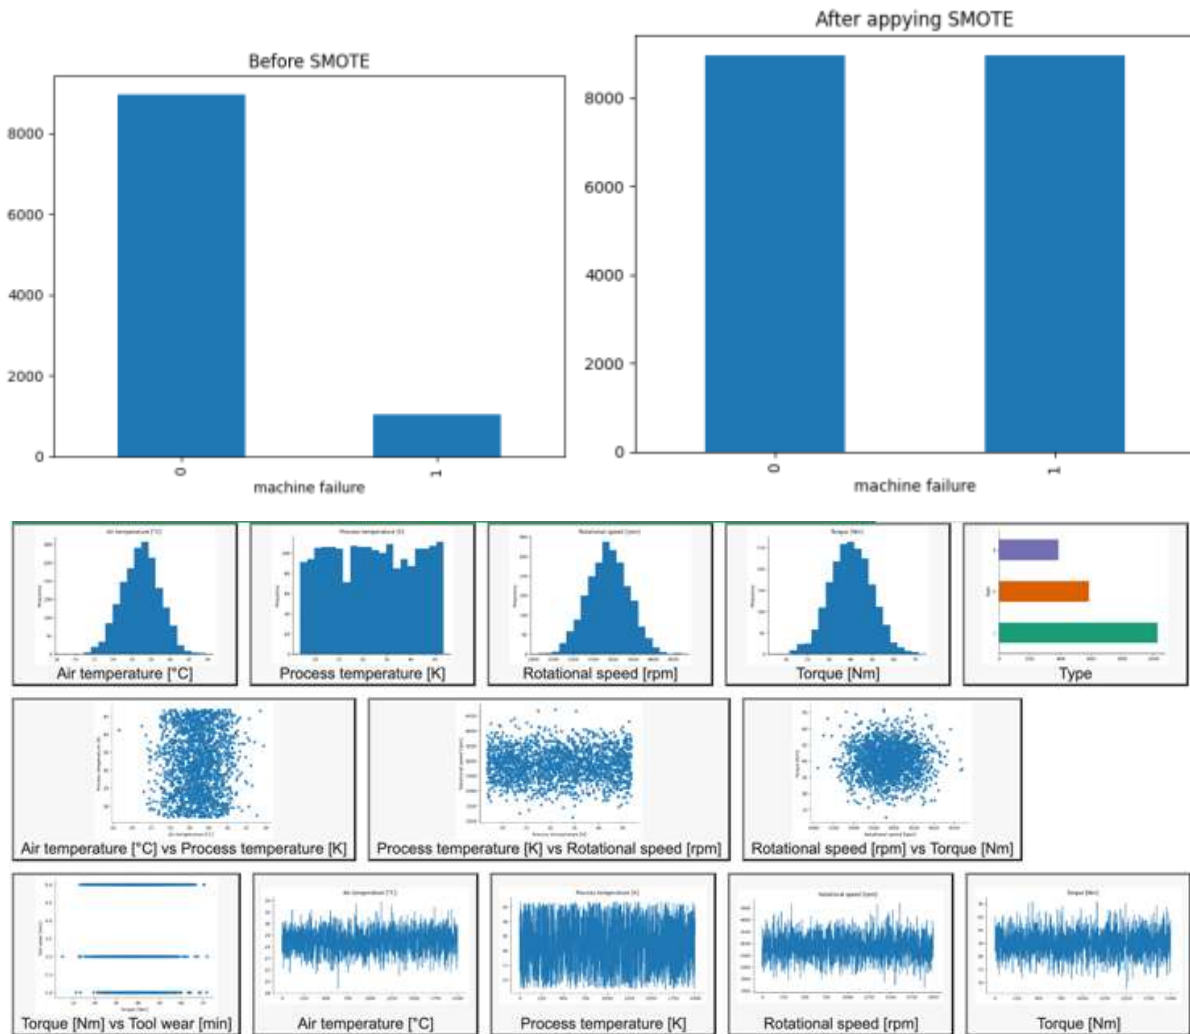
Pendekatan ini memungkinkan pemantauan kesehatan mesin secara kontinu serta deteksi dini terhadap potensi kegagalan mesin yang memerlukan tindakan pemeliharaan.

Selanjutnya, data yang tersedia dianalisis dan dikorelasikan menggunakan teknik machine learning. Pada tahap ini, peneliti memetakan kerangka kerja pemodelan yang dijadikan acuan untuk menyelesaikan permasalahan pada studi kasus. Proses dimulai dengan penentuan parameter-parameter yang relevan berdasarkan data yang diperoleh, kemudian dilanjutkan dengan tahapan *data preprocessing*, *data preparation*, dan *feature selection*. Setelah itu, dilakukan pemilihan algoritma klasifikasi, pembangunan model (*model building*), serta evaluasi kinerja model untuk menentukan model terbaik yang akan digunakan dalam mendeteksi kegagalan mesin.

Pendekatan bertahap ini memastikan bahwa setiap proses dalam alur analitik dilakukan secara sistematis dan terstruktur, sehingga model klasifikasi yang dihasilkan memiliki tingkat akurasi dan reliabilitas yang tinggi dalam mengidentifikasi kondisi kegagalan pada mesin milling.

Solusi yang diusulkan diimplementasikan dengan membagi dataset ke dalam dua bagian, yaitu 70% sebagai data pelatihan (*training data*) dan 30% sebagai data pengujian (*testing data*). Pembagian ini bertujuan untuk memastikan bahwa model mampu mempelajari pola data secara optimal sekaligus dievaluasi secara objektif terhadap data yang belum pernah dilihat sebelumnya.

Sebagaimana ditunjukkan pada Gambar 3, dari total 10.000 data, sebanyak 8.970 data merepresentasikan kondisi operasi mesin normal tanpa kegagalan, sedangkan 1.030 data lainnya menunjukkan kejadian kegagalan mesin. Distribusi data tersebut mencerminkan karakteristik permasalahan predictive maintenance yang umumnya bersifat imbalanced, di mana jumlah kondisi normal lebih dominan dibandingkan kondisi kegagalan.



Gambar 3. Perbandingan Dataset

	precision	recall	f1-score	support
0	0.89	1.00	0.94	1785
1	0.00	0.00	0.00	215
accuracy			0.89	2000
macro avg	0.45	0.50	0.47	2000
weighted avg	0.80	0.89	0.84	2000

Gambar 4. *Decision Tree Model*

	precision	recall	f1-score	support
0	0.89	1.00	0.94	1785
1	0.00	0.00	0.00	215
accuracy			0.89	2000
macro avg	0.45	0.50	0.47	2000
weighted avg	0.80	0.89	0.84	2000

Gambar 5. *Random Forest Model*

DecisionTrees's Accuracy: 0.804  
 Random Forest's Accuracy: 0.8925

Gambar 6. *Accuracy Model*

Dalam menganalisis kinerja model, dilakukan perbandingan tingkat akurasi antara model *Decision Tree* dan *Random Forest*. Hasil evaluasi menunjukkan bahwa model *Random Forest* memiliki akurasi yang lebih tinggi dibandingkan dengan model *Decision Tree*. Secara spesifik, model *Random Forest* mencapai tingkat akurasi sebesar 0,892, sedangkan model *Decision Tree* memperoleh akurasi sebesar 0,804. Oleh karena itu, pada tahap evaluasi selanjutnya diputuskan untuk memilih model *Random Forest* sebagai model prediktif. Keputusan ini didasarkan pada keunggulan kinerja *Random Forest* dalam menghasilkan prediksi yang akurat dan konsisten dengan data uji.

Pemilihan model *Random Forest* dinilai penting karena tingkat akurasinya yang lebih tinggi mampu menghasilkan keluaran prediksi yang lebih andal. Selain itu, keberhasilan model *Random Forest* dalam menangani data pengujian menjadi faktor penentu dalam proses pengambilan keputusan tersebut. Pemilihan model yang tepat merupakan langkah krusial dalam mengoptimalkan hasil prediksi serta meningkatkan kualitas model yang digunakan dalam konteks analisis atau tugas prediksi tertentu.


Setelah proses pemilihan model, dilakukan evaluasi lanjutan melalui penerapan *hyperparameter tuning* pada model *Random Forest*. Hasil evaluasi menunjukkan adanya perubahan tingkat akurasi dari 0,892 menjadi 0,8915. Perubahan ini menunjukkan bahwa penyesuaian *hyperparameter* berhasil meningkatkan kinerja model *Random Forest* sehingga menghasilkan prediksi yang lebih akurat dan andal. Evaluasi setelah *hyperparameter tuning* merupakan tahap lanjutan yang bertujuan untuk mengoptimalkan model, meningkatkan akurasi prediksi, serta memperkuat reliabilitas model dalam konteks analisis atau tugas prediksi yang dilakukan.

Best Parameters (Random Forest):  
 Best Score (Random Forest): 0.898  
 Accuracy (Random Forest): 0.8915  
 Accuracy with cross-validation: 0.90 with standard deviation 0.00

Gambar 7. *Best Parameter Score*

Setelah penerapan *cross-validation* sebagaimana ditunjukkan pada Gambar 10, terjadi penyesuaian yang signifikan pada metrik akurasi model *Random Forest*. Secara khusus, nilai akurasi yang sebelumnya berada pada angka 0,898 mengalami penurunan menjadi 0,891. Penurunan akurasi ini menegaskan pentingnya proses *cross-validation* dalam menilai ketahanan (*robustness*) dan kemampuan generalisasi model *machine learning*. Meskipun nilai akurasi awal sebesar 0,898 tampak menjanjikan, proses validasi mengungkapkan bahwa kinerja model tersebut berpotensi kurang stabil ketika diterapkan pada data yang belum pernah dilihat sebelumnya atau dalam kondisi yang berbeda.

Perbedaan ini menekankan bahwa *cross-validation* merupakan langkah krusial dalam evaluasi model, karena memungkinkan peneliti dan praktisi memperoleh pemahaman yang lebih mendalam mengenai kemampuan prediktif model yang sesungguhnya serta kapasitasnya dalam melakukan generalisasi terhadap data baru. Selain itu, penurunan akurasi yang teramati mendorong perlunya evaluasi ulang terhadap parameter model *Random Forest*, seperti kedalaman pohon (*tree depth*) atau kriteria pemisahan (*splitting criteria*), guna meningkatkan kinerjanya dan memastikan keandalannya dalam penerapan pada kondisi dunia nyata.



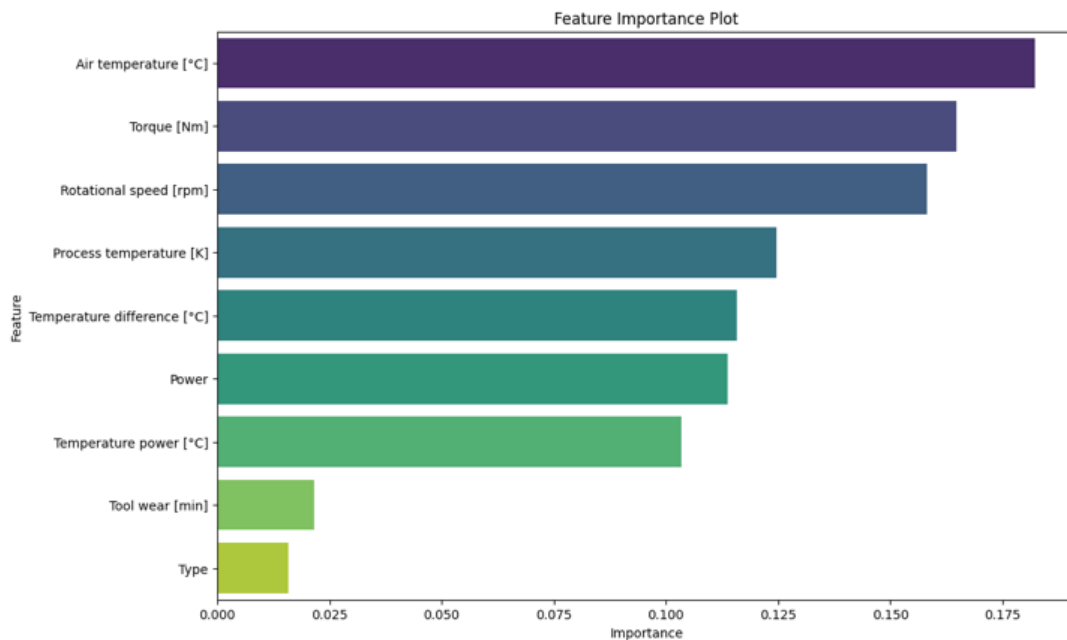
Gambar 8. ROC Score Random Forest (AUC)

Penting untuk melakukan penelaahan terhadap hasil evaluasi model Random Forest, khususnya dalam kerangka *Receiver Operating Characteristic (ROC)*. Skor ROC yang diperoleh sebesar 0,87 menunjukkan tingkat kinerja model yang tergolong baik. Skor ROC, atau yang dikenal sebagai *Area Under the Curve (AUC)*, merepresentasikan kemampuan model dalam membedakan antara kelas positif dan kelas negatif.

Analisis lebih lanjut terhadap kurva ROC menegaskan kinerja model Random Forest yang cukup kuat, yang ditunjukkan oleh nilai AUC sebesar 0,52. Nilai AUC yang mendekati satu mengindikasikan kemampuan model dalam menghasilkan prediksi yang sangat akurat, seiring dengan semakin dekatnya kurva ke sudut kiri atas grafik. Kurva ROC menggambarkan hubungan timbal balik antara true positive rate (sensitivitas) dan false positive rate ( $1 - \text{spesifisitas}$ ). Kedekatan kurva terhadap sudut kiri atas menunjukkan tingkat sensitivitas yang tinggi serta tingkat spesifisitas yang baik.

Keefektifan model Random Forest dalam memberikan kinerja yang unggul, sebagaimana tercermin dari nilai ROC dan AUC yang relatif tinggi, meningkatkan tingkat kepercayaan dalam memilih model ini untuk keperluan analisis atau prediksi yang dilakukan. Evaluasi lanjutan terhadap kinerja model dapat memberikan pemahaman yang lebih mendalam mengenai keandalan prediktif serta potensi penerapannya dalam berbagai konteks aplikasi. Oleh karena itu, evaluasi dan interpretasi metrik ini secara cermat menjadi aspek yang krusial dalam memahami kapabilitas model dan memastikan keandalannya untuk tujuan tertentu.

Plot *feature importance* menampilkan tingkat kepentingan berbagai fitur dalam sebuah dataset. Fitur-fitur yang ditunjukkan meliputi *air temperature*, *torque*, *rotational speed*, *process temperature*, *temperature difference*, *power*, *temperature power*, *tool wear*, dan *type*. Plot tersebut menggambarkan tingkat kepentingan masing-masing fitur dengan nilai yang berkisar antara 0,000 hingga 0,175.



Gambar 8. Plot *Feature Importance*.

#### 4. Kesimpulan

Berdasarkan hasil analisis komparatif yang telah dilakukan, dapat disimpulkan bahwa model *Random Forest* menunjukkan kinerja yang lebih unggul dibandingkan dengan model *Decision Tree* dalam mengklasifikasikan kondisi kegagalan mesin *Computer Numerical Control* (CNC). Hal ini ditunjukkan oleh nilai akurasi *Random Forest* sebesar 0,892, yang lebih tinggi dibandingkan dengan akurasi *Decision Tree* sebesar 0,804, serta konsistensi performa yang lebih baik pada berbagai metrik evaluasi. Hasil evaluasi menggunakan metrik *precision*, *recall*, *F1-score*, *confusion matrix*, serta analisis *Receiver Operating Characteristic* (ROC) menunjukkan bahwa *Random Forest* memiliki kemampuan generalisasi yang lebih baik dalam membedakan kondisi mesin normal dan gagal. Keunggulan ini diperkuat oleh penerapan hyperparameter tuning dan teknik cross-validation, yang memastikan bahwa model memiliki tingkat robustitas dan reliabilitas yang tinggi terhadap variasi data. Dengan demikian, *Random Forest* dinilai sebagai model yang paling sesuai untuk diterapkan dalam skema pemeliharaan prediktif mesin CNC pada penelitian ini. Temuan ini memberikan kontribusi penting dalam pemilihan model pembelajaran mesin berbasis pohon yang efektif untuk *predictive maintenance*, khususnya dari perspektif *data science* dan analisis prediktif. Penelitian selanjutnya dapat mengembangkan pendekatan ini dengan mempertimbangkan model berbasis deep learning atau data deret waktu untuk meningkatkan akurasi prediksi kegagalan mesin.

#### Referensi

- [1] S. Box and J. Lopez-Gonzalez, "The future of technology: Opportunities for ASEAN in the digital economy," *Glob. megatrends Implic. ASEAN Econ. community*, pp. 37–60, 2017.
- [2] D. G. S. Pivoto, L. F. F. de Almeida, R. da Rosa Righi, J. J. P. C. Rodrigues, A. B. Lugli, and A. M. Alberti, "Cyber-physical systems architectures for industrial internet of things applications in Industry 4.0: A literature review," *J. Manuf. Syst.*, vol. 58, pp. 176–192, 2021.
- [3] T. Czvetkó, A. Kummer, T. Ruppert, and J. Abonyi, "Data-driven business process management-based development of Industry 4.0 solutions," *CIRP J. Manuf. Sci. Technol.*, vol. 36, pp. 117–132, 2022.
- [4] W. Nugroho *et al.*, "Development of CNC Milling Machine for Small Scale Industry," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1068, no. 1, p. 012017, 2021, doi: 10.1088/1757-899x/1068/1/012017.
- [5] B. T. H. T. Baharudin, N. Dimou, and K. K. B. Hon, "Tool wear behaviour of micro-tools in high speed CNC machining," in

- Proceedings of the 34th International MATADOR Conference: Formerly The International Machine Tool Design and Conferences*, Springer, 2004, pp. 111–118.
- [6] M. Paolanti, L. Romeo, A. Felicetti, A. Mancini, E. Frontoni, and J. Loncarski, “Machine Learning approach for Predictive Maintenance in Industry 4.0,” *2018 14th IEEE/ASME Int. Conf. Mechatron. Embed. Syst. Appl. MESA 2018*, Aug. 2018, doi: 10.1109/MESA.2018.8449150.
- [7] W. Luo, T. Hu, Y. Ye, C. Zhang, and Y. Wei, “A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin,” *Robot. Comput. Integr. Manuf.*, vol. 65, p. 101974, 2020.
- [8] O. Surucu, S. A. Gadsden, and J. Yawney, “Condition Monitoring using Machine Learning: A Review of Theory, Applications, and Recent Advances,” *Expert Syst. Appl.*, vol. 221, no. February, p. 119738, Jul. 2023, doi: 10.1016/j.eswa.2023.119738.
- [9] S. Zhang, H. Dong, U. Maschek, and H. Song, “A digital-twin-assisted fault diagnosis of railway point machine,” *Proc. 2021 IEEE 1st Int. Conf. Digit. Twins Parallel Intell. DTPI 2021*, pp. 430–433, Jul. 2021, doi: 10.1109/DTPI52967.2021.9540118.
- [10] K. Y. Nazara, “Perancangan Smart Predictive Maintenance untuk Mesin Produksi,” *Semin. Nas. Off. Stat.*, vol. 2022, no. 1, pp. 691–702, 2022, doi: 10.34123/semnasoffstat.v2022i1.1575.
- [11] M. F. Süve, C. Gezer, and G. İnce, “Predictive Maintenance Framework for Production Environments Using Digital Twin,” *Lect. Notes Networks Syst.*, vol. 308, pp. 455–462, 2022, doi: 10.1007/978-3-030-85577-2\_54/TABLES/1.
- [12] W. Kritzing, M. Karner, G. Traar, J. Henjes, and W. Sihn, “Digital Twin in manufacturing: A categorical literature review and classification,” *IFAC-PapersOnLine*, vol. 51, no. 11, pp. 1016–1022, Jan. 2018, doi: 10.1016/j.ifacol.2018.08.474.
- [13] R. Saravanan and P. Sujatha, “A state of art techniques on machine learning algorithms: a perspective of supervised learning approaches in data classification,” in *2018 Second international conference on intelligent computing and control systems (ICICCS)*, IEEE, 2018, pp. 945–949.
- [14] D. Awari, M. Bhamare, A. Ghanwat, K. Jadhav, and J. Chahande, “Methodology for Selecting Components for Fabricating CNC Milling Machine for Small Scale Industry,” *Int. J. Sci. Res. Dev.*, vol. 4, no. 11, pp. 168–171, 2017.
- [15] Y. Jiang *et al.*, “Tool Wear Prediction Upgrade Kit for Legacy CNC Milling Machines in the Shop Floor,” in *Proceedings of the Conference on Production Systems and Logistics: CPSL 2022*, Hannover: publish-Ing., 2022, pp. 131–140.