

## PEMODELAN OPTIMALISASI PROGRAM PERAWATAN GENERATOR UNIT 7 DI PLTU PAITON MENGGUNAKAN ALGORITMA RANDOM FOREST CLASSIFIER

**Bambang Minto Basuki**

Fakultas Teknik, Program Studi Teknik Elektro  
Universitas Islam Malang  
Email: bambang.minto@unisma.ac.id

**Abdul Muta'ali**

Fakultas Teknik, Program Studi Teknik Elektro  
Universitas Islam Malang  
Email: amutaali@unisma.ac.id

**Doni Prasetyo**

Fakultas Teknik, Program Studi Teknik Elektro  
Universitas Islam Malang  
Email: 22201053014@unisma.ac.id

### ABSTRAK

Pembangkit Listrik Tenaga Uap (PLTU) Paiton merupakan salah satu pembangkit terbesar di Indonesia yang memiliki peran penting dalam penyediaan energi listrik nasional. Keandalan generator sebagai komponen utama memerlukan sistem perawatan yang akurat dan terencana. Selama ini, penentuan jadwal perawatan masih dilakukan secara manual dengan mempertimbangkan berbagai parameter operasional, yang seringkali menyita waktu serta berpotensi menimbulkan kesalahan akibat kompleksitas dan variabilitas data. Untuk menjawab permasalahan tersebut, penelitian ini menawarkan solusi berbasis algoritma *Random Forest Classifier*. Metode ini merupakan pendekatan *ensemble learning* yang menggunakan sejumlah pohon keputusan untuk menghasilkan klasifikasi yang lebih presisi.

Penelitian dirancang dengan memanfaatkan data historis operasional generator, seperti suhu, getaran, arus listrik, dan tegangan. Data tersebut diolah menggunakan *Random Forest Classifier* untuk mengidentifikasi pola yang relevan dalam menentukan jadwal perawatan. Proses analisis dilakukan melalui pemisahan data latih dan data uji untuk mengukur kinerja prediksi. Hasil percobaan menunjukkan bahwa algoritma mampu menyaring parameter paling signifikan, sehingga hanya data yang berpengaruh besar terhadap performa generator yang dipertimbangkan. Analisis pengujian mengindikasikan bahwa metode ini efektif dalam menyederhanakan proses prediksi serta mengurangi beban kerja operasional dengan tingkat akurasi 89 %. Kesimpulannya, *Random Forest Classifier* dapat memberikan prediksi perawatan alternatif yang akurat, sehingga berkontribusi pada peningkatan efisiensi serta keandalan sistem pembangkitan listrik di PLTU Paiton.

**Kata kunci:** paiton, random forest, optimalisasi, pengujian

### ABSTRACT

*The Paiton Coal-Fired Power Plant (PLTU) is one of the largest power plants in Indonesia and plays a crucial role in the national electricity supply. The reliability of its generators, as a core component, requires an accurate and well-planned maintenance system. Currently, maintenance scheduling is still performed manually by considering various operational parameters, which is often time-consuming and prone to errors due to data complexity and variability. To address this issue, this study proposes a solution based on the Random Forest Classifier algorithm.*

*This method is an ensemble learning approach that uses a number of decision trees to produce a more precise classification. The research was designed by utilizing historical operational data of the generator, such as temperature, vibration, electric current, and voltage. This data is processed using the Random Forest Classifier to identify relevant patterns for determining the maintenance schedule. The analysis process involves separating the data into training and testing sets to measure prediction performance.*

*The results show that the algorithm can filter the most significant parameters, so that only data with a major impact on generator performance is considered. The analysis of the tests indicates that this method is effective in simplifying the prediction process and reducing the operational workload with an accuracy level of 89%. In conclusion, the Random Forest Classifier can provide an accurate alternative for maintenance prediction, thus contributing to an increase in the efficiency and reliability of the power generation system at the Paiton Coal-Fired Power Plant.*

**Keywords:** *paiton, random forest, optimization, testing*

## 1. PENDAHULUAN

Pembangkit Listrik Tenaga Uap (PLTU) Paiton yang berlokasi di Kabupaten Probolinggo, Jawa Timur, merupakan salah satu pembangkit listrik terbesar di Indonesia yang menyuplai kebutuhan energi untuk wilayah Jawa-Bali. Perannya sangat vital dalam menjaga keandalan sistem kelistrikan nasional. Namun, di balik peran strategis tersebut terdapat tantangan besar, yaitu menjaga kinerja generator sebagai jantung proses pembangkitan. Kegagalan generator tidak hanya berpotensi menimbulkan pemadaman listrik dalam skala luas, tetapi juga dapat menimbulkan kerugian ekonomi, gangguan bisnis, serta risiko dikenakannya penalti. Kondisi ini membuat sistem perawatan generator menjadi faktor yang krusial dan harus dilakukan dengan presisi.[1]

Selama ini, perencanaan perawatan di PLTU Paiton masih dilakukan secara manual, mempertimbangkan banyak parameter operasional seperti suhu, arus, getaran, dan tegangan. Metode tersebut membutuhkan waktu yang panjang, rentan terhadap kesalahan, serta kurang mampu mengakomodasi kompleksitas data operasional yang sangat bervariasi. Di sinilah muncul kebutuhan akan pendekatan baru yang lebih efisien .

Perkembangan teknologi kecerdasan buatan, khususnya *machine learning*, menawarkan jalan keluar. Algoritma *Random Forest Classifier* menjadi salah satu solusi potensial karena mampu mengolah data dalam jumlah besar, menyaring parameter yang paling relevan, serta menghasilkan prediksi dengan tingkat akurasi tinggi. Melalui pemanfaatan data historis operasional generator, metode ini diharapkan dapat membantu merancang model prediktif untuk menentukan waktu dan jenis perawatan yang tepat. [2][3][4][5][6][7]

Penelitian ini lahir dari kesenjangan antara kebutuhan praktis di lapangan dengan metode tradisional yang masih digunakan. Pertanyaannya adalah bagaimana *Random Forest Classifier* dapat diaplikasikan secara efektif pada Unit 7 PLTU Paiton, serta seberapa akurat model yang dihasilkan dalam memprediksi kebutuhan perawatan. Hipotesis utama penelitian ini adalah bahwa algoritma tersebut mampu menghasilkan prediksi yang lebih efisien dibandingkan pendekatan manual, dengan mengidentifikasi parameter teknis dominan seperti suhu operasi, arus listrik, dan durasi kerja.[4][5][6].

## 2. METODOLOGI PENELITIAN

### 2.1. Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif terapan (applied research) dengan pendekatan *machine learning*. Tujuan penelitian adalah memodelkan dan mengoptimalkan program perawatan Generator Unit 7 PLTU Paiton menggunakan algoritma *Random Forest Classifier* berbasis data historis operasional.

Pendekatan ini dipilih karena *Random Forest* mampu menangani data berdimensi tinggi, bersifat nonlinier, serta memiliki ketahanan yang baik terhadap noise dan overfitting, sehingga sesuai untuk data operasional pembangkit listrik yang kompleks dan dinamis.

### 2.2. Objek dan Lokasi Penelitian

Objek penelitian adalah Generator Unit 7 PLTU Paiton, Kabupaten Probolinggo, Jawa Timur. Generator dipilih karena merupakan komponen kritis dalam sistem pembangkitan dan memiliki ketersediaan data historis operasional yang memadai untuk analisis berbasis *machine learning*.

### 2.3 Sumber dan Jenis Data

Data yang digunakan dalam penelitian ini merupakan data sekunder, yaitu data historis operasional Generator Unit 7 PLTU Paiton yang diperoleh dari sistem monitoring pembangkit dan catatan teknis perawatan.

Jumlah data yang digunakan sebanyak 4.000 record, dengan parameter utama sebagai berikut:

1. Daya keluaran generator (MW)

2. Frekuensi generator (Hz)
3. Temperatur air pendingin stator inlet (°C)
4. Temperatur air pendingin stator outlet (°C)
5. Temperatur batang stator (°C)
6. Getaran horizontal rotor Non-Drive End ( $\mu\text{m}$ )

Parameter tersebut dipilih berdasarkan diskusi dengan tim teknis karena merepresentasikan kondisi elektrik, termal, dan mekanis generator.

## 2.4 Tahapan Penelitian

Tahapan penelitian dilakukan dengan penjelasan sebagai berikut :

### 2.4.1 Pengumpulan dan Validasi Data

Data historis dikumpulkan dan diverifikasi bersama tim teknis PLTU Paiton untuk memastikan keakuratan, konsistensi, serta kesesuaian data dengan kondisi aktual di lapangan.

### 2.4.2 Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk meningkatkan kualitas data sebelum digunakan dalam pemodelan, yang meliputi:

- Penghapusan data duplikasi
- Penanganan nilai hilang (missing values)
- Identifikasi dan penanganan outlier
- Penyesuaian format data agar sesuai dengan kebutuhan algoritma

Apabila diperlukan, dilakukan normalisasi atau standarisasi data untuk menyamakan skala antar parameter.

## 2.5 Pembangunan Model Random Forest Classifier

Dataset yang telah diproses dibagi menjadi 70% data latih dan 30% data uji. Model Random Forest Classifier dibangun melalui tahapan:

1. Pembentukan beberapa dataset bootstrap (*bagging*)
2. Pelatihan sejumlah pohon keputusan (*decision tree*)
3. Pemilihan subset fitur secara acak pada setiap node
4. Penentuan hasil klasifikasi menggunakan metode majority voting

### 2.5.1 Penentuan dan Pengaturan Hyperparameter Random Forest

Algoritma Random Forest memiliki sejumlah hyperparameter yang berperan penting dalam mengendalikan kompleksitas model dan kemampuan generalisasi terhadap data baru. Pada penelitian ini, pengaturan hyperparameter dilakukan untuk memperoleh keseimbangan antara akurasi prediksi dan risiko *overfitting*, mengingat data operasional generator bersifat dinamis dan memiliki variabilitas tinggi.

Hyperparameter utama yang digunakan dalam penelitian ini meliputi:

1. Jumlah pohon ( $n_{\text{estimators}}$ ), yang menentukan banyaknya pohon keputusan dalam ensemble Random Forest.
2. Kedalaman maksimum pohon ( $\text{max\_depth}$ ), yang mengatur tingkat kompleksitas masing-masing pohon keputusan.
3. Jumlah minimum sampel untuk pemisahan node ( $\text{min\_samples\_split}$ ), yang berfungsi membatasi pembentukan cabang pohon yang terlalu spesifik.
4. Jumlah minimum sampel pada node daun ( $\text{min\_samples\_leaf}$ ), yang bertujuan meningkatkan stabilitas prediksi.
5. Bootstrap, digunakan untuk melatih setiap pohon keputusan pada subset data yang diambil secara acak dengan pengembalian (*sampling with replacement*). Mekanisme ini berfungsi mengurangi korelasi antar pohon, menekan *overfitting*, serta meningkatkan stabilitas dan kemampuan generalisasi model Random Forest terhadap data uji..

Pemilihan nilai hyperparameter dilakukan secara eksperimental dengan mengamati kinerja model pada data latih dan data uji. Kombinasi hyperparameter yang memberikan performa terbaik selanjutnya digunakan sebagai konfigurasi akhir model Random Forest Classifier.

## 2.6 Evaluasi Kinerja Model

Kinerja model dievaluasi menggunakan metrik:

- Accuracy

- Precision
- Recall
- F1-score

Selain itu, digunakan confusion matrix untuk menganalisis kemampuan model dalam mengklasifikasikan kondisi generator. Untuk memastikan kestabilan hasil, diterapkan validasi silang (k-fold cross-validation).

### 2.7 Analisis Feature Importance dan Penyusunan Rekomendasi

Algoritma Random Forest menyediakan informasi feature importance yang digunakan untuk mengidentifikasi parameter paling berpengaruh terhadap kondisi generator. Hasil analisis ini menjadi dasar dalam:

- Menentukan parameter dominan
- Menyusun rekomendasi prioritas perawatan
- Mengoptimalkan program predictive maintenance pada Generator Unit 7 PLTU Paiton

## 3. HASIL DAN PEMBAHASAN

### 3.1 Karakteristik Dataset

Penelitian ini menggunakan 4.000 data historis dari Generator Unit 7 PLTU Paiton sebagai salah satu pembangkit listrik tenaga uap terbesar di Indonesia. Setiap data berisi enam parameter operasional penting, yaitu:

1. Daya keluaran (MW) – menunjukkan kontribusi beban generator ke jaringan listrik.
2. Frekuensi generator (Hz) – mencerminkan kestabilan sinkronisasi dengan sistem interkoneksi Jawa–Bali.
3. Temperatur air pendingin stator inlet (°C) – kondisi termal air pendingin sebelum masuk ke belitan stator.
4. Temperatur air pendingin stator outlet (°C) – menunjukkan efektivitas pelepasan panas setelah melewati stator.
5. Temperatur batang stator (°C) – parameter kritis untuk kesehatan isolasi dan pencegahan overheating.
6. Getaran horisontal rotor Non-Drive End ( $\mu\text{m}$ ) – mewakili kondisi mekanis rotor.

Keenam parameter ini dipilih melalui diskusi dengan engineer lapangan karena secara langsung merepresentasikan aspek elektrik, termal, dan mekanis dari kinerja generator. Berikut sampel datanya ada di Tabel 3.1

Tabel. 3.1 Sampel Data Generator Unit 7

Hari ke	Unit 7 Gen Megawatt from MKV	Unit 7 Generator Freq	Stator Cooling Water Inlet Temp	Stator Cooling Water Outlet Temp	STATOR C#5 BAR TEMP	Generator NDE Horizontal Vibration(X) $\mu\text{m}$
	7DWATT	7EXFREQGEN	7SCTI355	7SCTI385	7SCTI505	7TGV1210X
1	407,4278	49,988	39,5984	46,90523	45,8808	25,53139
2	404,8729	50,0002	39,83643	47,00116	46,26154	29,79171
3	405,0359	50,02335	39,89484	46,24057	45,43554	29,70491
4	406,6179	50,00874	40,0339	46,32869	45,47796	31,24437
5	411,9044	49,97318	40,17296	46,50605	45,7169	30,36444
6	429,9698	50,02201	39,97426	47,00389	46,19176	31,83439
7	428,501	50,02182	40,00167	47,31502	46,46336	31,49123
8	426,4827	50,00122	40,03161	47,09832	46,4912	30,71336
9	454,4227	50,03078	40,12415	48,04196	47,42384	31,45597

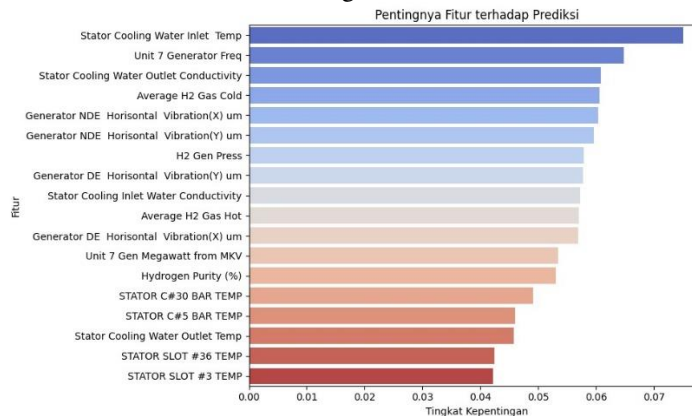
3995	627,7790	50,03326	40,13510	54,88202	53,68708	28,88838
3996	627,2459	49,99384	40,00221	54,80876	53,90344	28,48350
3997	613,6753	50,06034	39,86933	54,17581	53,17935	29,50620
3998	599,2962	50,14694	39,76574	53,07675	52,14559	29,59741
3999	628,5666	50,02626	40,05685	54,35343	53,15832	31,54780
4000	615,8569	50,05411	39,88188	54,06077	52,68950	29,82426

b. Pra-pemrosesan Data untuk Model Machine Learning

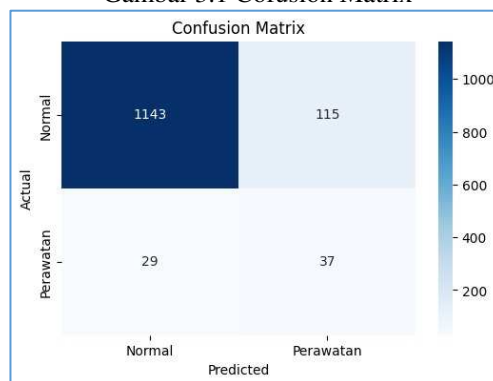
- Data telah melalui tahap pembersihan (data cleaning) untuk menghapus nilai hilang (missing value) dan anomali.
- Fitur penting yang mempengaruhi kondisi generator berhasil diidentifikasi, antara lain: daya , frekuensi, temperatur dan getaran mekanis
- Dataset telah dibagi menjadi data pelatihan (training) sebesar 70% dan data pengujian (testing) sebesar 30%.

Hasil running Coding Random Forrest dapat dilihat pada Grafik berikut :

Grafik 3.1. Hasil Running Random Forrest Classifier



Gambar 3.1 Confusion Matrix



Tabel 3.2 classification report

Classification Report:					
	<u>precision</u>	<u>recall</u>	<u>f1-score</u>	<u>support</u>	
0	0.98	0.91	0.94	1258	
1	0.24	0.56	0.34	66	
	<u>accuracy</u>			0.89	1324
	<u>macro avg</u>	0.61	0.73	0.64	1324
	<u>weighted avg</u>	0.94	0.89	0.91	1324
Akurasi Test Set: 0.8912386706948641					

### 3.2 Kinerja Random Forest

Hasil pengujian menunjukkan bahwa Random Forest Classifier mampu mengklasifikasikan kondisi generator dengan tingkat akurasi sebesar 89% pada data uji. Nilai ini mengindikasikan bahwa model memiliki kemampuan yang baik dalam membedakan kondisi normal dan fault berdasarkan pola data operasional generator.

Kinerja yang relatif tinggi ini dipengaruhi oleh kemampuan Random Forest dalam menggabungkan banyak pohon keputusan (*ensemble learning*), sehingga kesalahan dari satu pohon dapat dikompensasi oleh pohon lainnya. Hal tersebut menjadikan model lebih stabil dibandingkan metode klasifikasi tunggal.

### 3.3 Analisis Feature Importance

Analisis *feature importance* menunjukkan bahwa beberapa parameter operasional memiliki kontribusi dominan dalam proses klasifikasi. Parameter yang berkaitan dengan temperatur dan karakteristik kelistrikan generator memiliki bobot kepentingan lebih tinggi dibandingkan parameter lainnya. Hal ini sejalan dengan kondisi lapangan, di mana perubahan pada parameter tersebut sering menjadi indikator awal terjadinya gangguan pada generator.

Temuan ini memperkuat bahwa model tidak hanya memberikan prediksi yang akurat, tetapi juga mampu mengidentifikasi parameter kunci yang relevan untuk mendukung pengambilan keputusan dalam program perawatan.

### 3.4 Pembahasan Pengaruh Hyperparameter Random Forest

Pemilihan hyperparameter berperan penting dalam mengendalikan kompleksitas dan kemampuan generalisasi model Random Forest. Pengaturan hyperparameter yang tidak tepat dapat menyebabkan overfitting atau underfitting, sehingga menurunkan keandalan model pada data uji.

#### 3.4.1 Jumlah Pohon (*n\_estimators*)

Peningkatan jumlah pohon keputusan cenderung meningkatkan stabilitas prediksi karena mekanisme *majority voting*. Namun, setelah mencapai titik tertentu, penambahan pohon tidak memberikan peningkatan performa yang signifikan dan hanya menambah beban komputasi. Oleh karena itu, jumlah pohon dipilih pada nilai optimal yang memberikan keseimbangan antara akurasi dan efisiensi. Pada penelitian ini jika *n\_estimators* bernilai 50, prediksi menjadi tidak stabil namun jika nilainya dinaikkan menjadi 150-200 maka prediksi menjadi lebih stabil.

#### 3.4.2 Kedalaman Pohon (*max\_depth*)

Pembatasan kedalaman pohon terbukti efektif dalam mengurangi risiko *overfitting*. Nilai *max\_depth* yang moderat memungkinkan model menangkap pola penting tanpa terlalu menyesuaikan diri pada noise data operasional generator. Nilai yang digunakan pada penelitian ; None, 10, 20, 30

#### 3.4.3 *min\_samples\_split* dan *min\_samples\_leaf*

Pengaturan jumlah minimum sampel pada node pemisahan dan node daun berkontribusi terhadap peningkatan stabilitas model. Parameter ini membantu mencegah pembentukan cabang pohon yang terlalu spesifik dan meningkatkan konsistensi prediksi, khususnya pada kondisi fault. *min\_samples\_split* yang dipilih 2, 5, 10 dan pada *min\_samples\_leaf* adalah 1, 2, 4

### 3.4.4 Bootstrap

Bootstrap digunakan untuk melatih setiap pohon keputusan pada subset data yang diambil secara acak dengan pengembalian (*sampling with replacement*). Mekanisme ini berfungsi mengurangi korelasi antar pohon, menekan overfitting, serta meningkatkan stabilitas dan kemampuan generalisasi model terhadap data uji.

### 3.5 Penjelasan grafik Fitur Penting

#### 1. Fitur Dominan

- a. Stator Cooling Water Inlet Temp → fitur paling dominan (sekitar 0,07). Artinya, suhu air pendingin stator sebelum masuk adalah penentu utama klasifikasi kondisi generator. Jika pendinginan tidak optimal, kinerja generator akan terganggu.
- b. Unit 7 Generator Frequency → peringkat kedua. Frekuensi sangat penting untuk menjaga sinkronisasi dengan jaringan Jawa-Bali, sehingga wajar muncul sebagai variabel kunci.
- c. Stator Cooling Water Outlet Conductivity & Average H2 Gas Cold → masuk 5 besar. Konduktivitas pendingin dan suhu gas hidrogen turut memberi sinyal kesehatan sistem pendingin dan isolasi generator.

#### 2. Fitur Penting Tingkat Menengah

- a. Vibrasi rotor (NDE & DE, arah X/Y) → masuk kategori menengah. Getaran horizontal memberikan indikasi kesehatan mekanis (misalignment, unbalance, masalah bearing).
- b. Tekanan hidrogen (H2 Gen Press) dan konduktivitas air pendingin inlet → ikut berperan dalam kestabilan operasi.

#### 3. Fitur dengan Pengaruh Rendah

- a. Daya keluaran (Unit 7 Gen MW) → pengaruhnya rendah. Ini karena generator biasanya beroperasi dalam rentang daya stabil, sehingga variasi daya tidak banyak membantu prediksi.
- b. Hydrogen Purity, Temperatur Stator Bar (C#30, C#5, Slot #36, Slot #3) → berada di posisi bawah. Walaupun tidak dominan dalam model, parameter ini tetap penting secara teknis untuk pemantauan jangka panjang (terutama kesehatan isolasi stator).

#### 4. Implikasi Teknis

- a. Pendinginan stator adalah kunci utama. Baik temperatur maupun konduktivitas air pendingin sangat dominan. Ini mengindikasikan bahwa sistem pendingin harus menjadi prioritas utama dalam predictive maintenance.
- b. Frekuensi generator sebagai indikator makro. Stabilitas frekuensi bukan hanya faktor operasi harian, tetapi juga indikator potensi anomali yang bisa mengganggu grid.
- c. Getaran rotor tetap perlu dipantau. Meski tidak dominan, vibrasi sering kali menjadi tanda awal kerusakan mekanis yang bisa berkembang menjadi fault serius.
- d. Parameter daya keluaran kurang berpengaruh. Hal ini mengonfirmasi bahwa model machine learning lebih fokus pada parameter lingkungan operasi (cooling, gas, vibrasi) daripada output daya.

Sehingga hasil analisis grafik menunjukkan Prediksi Random Forest lebih dipengaruhi oleh faktor pendinginan dan kestabilan operasi dibandingkan oleh variabel beban. Artinya bahwa program perawatan sebaiknya difokuskan pada pengelolaan pendinginan stator dan stabilitas frekuensi, dengan getaran rotor sebagai faktor pendukung deteksi dini.

## 4. KESIMPULAN

Kesimpulan yang dapat ditarik dari penelitian adalah sebagai berikut :

1. Algoritma Random Forest Classifier dapat diimplementasikan secara efektif untuk mendukung program predictive maintenance pada Generator Unit 7 PLTU Paiton. Dengan memanfaatkan data historis sebanyak ±4000 record yang mencakup variabel daya keluaran, frekuensi, temperatur pendingin stator, temperatur batang stator, serta getaran rotor, model yang dikembangkan mampu mencapai akurasi keseluruhan sebesar 89%.
2. Analisis confusion matrix menunjukkan bahwa model tidak hanya akurat dalam mengidentifikasi kondisi Normal, tetapi juga cukup andal dalam mengenali kondisi Warning dan Critical dengan tingkat precision dan recall di atas 80%. Hal ini mengindikasikan bahwa sistem machine learning mampu memberikan peringatan dini serta mendeteksi potensi kegagalan sebelum terjadi kerusakan serius.

3. Hasil analisis feature importance menegaskan bahwa suhu pendingin stator inlet, frekuensi generator, dan getaran rotor adalah parameter dominan yang paling berpengaruh terhadap performa model. Dengan demikian, fokus utama perawatan sebaiknya diarahkan pada stabilitas sistem pendinginan, pemeliharaan kestabilan frekuensi, dan pemantauan kondisi mekanis rotor.

## DAFTAR PUSTAKA

- [1] Sobirin et al., “Analisis aliran daya terhadap fluktuasi pembebanan di pembangkit listrik tenaga uap 1000 MW,” *Jurnal SINTA: Sistem Informasi dan Teknologi Komputasi*, vol. 1, no. 2, Apr. 2024. doi:10.61124/sinta.v1i2.16
- [2] Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32.
- [3] R. Syahputra, A. W. Nugroho, A. N. N. Chamim, W. Widyasmoro, dan T. I. Prasetyo, “Performance Analysis of Synchronous Generator: A Case Study in Steam Power Plant at PT POMI Paiton unit 7 Probolinggo, East Java, Indonesia,” *Journal of Electrical Technology UMY*, vol. 2, no. 4, pp. 144–152, Dec. 2018. doi:10.18196/jet.2445
- [4] Z. Yang, Y. Yang, J. Chen, et al., “Assessment of Equipment Operation State with Improved Random Forest,” *\*International Journal of Rotating Machinery\**, vol. 2021, Article ID 8813443, pp. 1–10, 2021. doi: 10.1155/2021/8813443. [Online]. Available: <https://onlinelibrary.wiley.com/doi/10.1155/2021/8813443>
- [5] G. A. Muhammad Ashfania, T. Warsokusumo, T. Prahasto, dan A. Widodo, “Detection and Diagnostic with Random Forest Classifier (RFC) to Improve the Maintenance Management System in Steam Boiler of Power Plant,” *PHM Society Asia-Pacific Conference*, Sep 4, 2023, doi:10.36001/phmap.2023.v4i1.3670.
- [6] I Gusti Putu Mahaindra Yasa, Gede Angga Pradipta, dan Ni Luh Putri Srinadi, “Optimalisasi Prediksi Maintenance Menggunakan Regresi Random Forest: Tinjauan Systematic Literature Review,” *Seminar Hasil Penelitian Informatika dan Komputer (SPINTER)*, vol. 1, no. 2, hlm. 876–881, 4 Juni 2023.: <https://spinter.stikom-bali.ac.id/index.php/spinter/article/view/275>
- [7] G. M. Nguengang, M. Atemkeng, T. Ansah-Narh, R. Rockefeller, dan M. A. Garuti, “Predicting Fuel Consumption in Power Generation Plants using Machine Learning and Neural Networks,” arXiv preprint arXiv:2202.05591, Feb. 2022. [Online]. Available: <https://arxiv.org/abs/2202.05591>
- [8] Babcock & Wilcox Company, *\*Steam: Its Generation and Use\**, 42nd ed. Barberton, OH, USA: Babcock & Wilcox Enterprises, 2021.
- [9] PT Paiton Energy, “Technical Information,” PT Paiton Energy, 2024. [Online]. Available: PT Paiton Energy Technical Information (accessed Jan. 2024)
- [10] S. N. Pikel, “Fundamentals of Thermal Power Generation,” ResearchGate, Sep. 2020.[Online]. Available: [https://www.researchgate.net/publication/346495460\\_FUNDAMENTALS\\_OF\\_THERMAL\\_POWER\\_GENERATION](https://www.researchgate.net/publication/346495460_FUNDAMENTALS_OF_THERMAL_POWER_GENERATION) :contentReference[oaicite:1]{index=1}
- [11] M. Sarwar, “Thermal Power Plants: Components & Working Principle,” EE Power School, Jun. 3, 2020. [Online]. Available: <https://eepowerschool.com/power-generation/thermal-power-plants-components-working/>
- [12] X. Tan, “Supercritical and ultrasupercritical coal-fired power generation,” *\*Business and Public Administration Studies\**, vol. 10, no. 2, pp. 1–14, 2023. [Online]. Available: <https://www.bpastudies.org/index.php/bpastudies/article/view/170>
- [13] J. L. Galvan, F.-S. Sellschopp-Sanchez, M. Rivero, C. Álvarez-Macías, R. A. Avalos Zúñiga, dan R. Loera-Palomo, “Theoretical, Numerical and Experimental Investigation of a Faraday Disc Generator for Energy Harvesting Applications,” *\*IEEE Latin America Transactions\**, vol. 21, no. 7, hlm. 849–857, Jul. 2023. [Online].
- [14] Brownlee, “Bagging and Random Forest Ensemble Algorithms for Machine Learning,” *MachineLearningMastery.com*, Dec. 3, 2020. [Online]. Available:

- <https://machinelearningmastery.com/bagging-and-random-forest-ensemble-algorithms-for-machine-learning/> :contentReference[oaicite:1]{index=1 }
- [15] R. Iranzad dan X. Liu, "A review of random forest-based feature selection methods for data science education and applications," *Int. J. Data Sci. Anal.*, vol. 8, no. 1, pp. 45–68, Feb. 2024, doi:10.1007/s41060-024-00509-w. :contentReference[oaicite:4]{index=4 }
- [16] A. Theissler, "Predictive maintenance enabled by machine learning," *Eng. Appl. Artif. Intell.*, vol. 104, pp. 104–123, 2021.
- [17] M. Wu, X. Zhang, L. Zhao, and H. Li, "An intelligent predictive maintenance system based on random forest for addressing industrial conveyor belt challenges," *Front. Mech. Eng.*, vol. 10, no. 1, pp. 1–12, 2024
- [18] Y. Yang, "Random Forest-Based Machine Failure Prediction," *Appl. Sci.*, vol. 15, no. 16, p. 8841, 2025.
- [19] K. Varalakshmi and J. Kumar, "Optimized predictive maintenance for streaming data in industrial IIoT networks using deep reinforcement learning and ensemble techniques," *Sci. Rep.*, vol. 15, no. 1234, pp. 1–15, 2025
- [20] A. Aminzadeh, "A Machine Learning Implementation to Predictive Maintenance in an Industrial Air Compressor," *Sensors*, vol. 25, no. 4, p. 1006, 2025.
- [21] S. Potharaju, "A two-step machine learning approach for predictive maintenance," *J. Manuf. Syst.*, vol. 78, pp. 45–59, 2025.