



Pemodelan Prediktif *Plugging Pulverizer* PLTU Indramayu Berbasis *Random Forest Classifier*

Agus Mustofa¹, Purwatingtyas²

^{1,2}Fakultas Teknologi Informasi dan Industri, Universitas Stikubank Semarang, Indonesia
Email: Agusmustofa6009@mhs.unisbank.ac.id¹, purwati@edu.unisbank.ac.id²

Abstract

Indramayu Steam Power Plant (PLTU Indramayu) is one of the strategic power generation facilities that plays a vital role in supplying national electrical energy. One of the operational issues frequently encountered in the power generation system is *Plugging* in the Pulverizer, which refers to the blockage of coal flow inside the mill. This condition can lead to reduced combustion performance, increased equipment load, and even unit trip events. Therefore, an early detection and prediction system for *Plugging* conditions based on operational data is required. This study aims to develop a *Plugging* forecasting system for the Pulverizer at PLTU Indramayu using the *Random Forest Classifier* method. The data used in this research were obtained from historical Pulverizer operational records, including mill motor current, coal flow rate, primary air flow rate, and mill outlet temperature. The research stages consist of initial data preprocessing, feature selection, labeling of operating conditions (normal and *Plugging*), and model testing using the *Random Forest Classifier* algorithm. Model performance was evaluated using accuracy, precision, recall, F1-score, and cross-validation metrics. The results show that the *Random Forest Classifier* model is capable of classifying *Plugging* conditions with high and stable accuracy, indicating its effectiveness as a decision-support tool for predictive maintenance systems. With the implementation of this system, operators are expected to take preventive actions at an earlier stage, thereby minimizing operational disturbances and enhancing the reliability of the power generation system.

Keywords: *Random Forest Classifier, Pulverizer Plugging, PLTU Indramayu, Machine Learning, Predictive Maintenance*

Abstrak

Pembangkit Listrik Tenaga Uap (PLTU) Indramayu merupakan salah satu pembangkit strategis yang berperan penting dalam penyediaan energi listrik nasional. Salah satu permasalahan operasional yang sering terjadi pada sistem pembangkitan adalah *Plugging* pada Pulverizer, yaitu kondisi penyumbatan aliran batubara di dalam mill yang dapat menyebabkan penurunan kinerja pembakaran, peningkatan beban peralatan, hingga terjadinya trip unit. Oleh karena itu, diperlukan suatu sistem yang mampu mendeteksi dan memprediksi kondisi *Plugging* secara dini berbasis data operasional. Penelitian ini bertujuan untuk mengembangkan sistem forecasting *Plugging* pada Pulverizer PLTU Indramayu menggunakan metode *Random Forest Classifier*. Data yang digunakan berasal dari histori operasi Pulverizer berupa parameter arus motor mill, aliran batubara, aliran udara primer, serta temperatur outlet mill. Tahapan penelitian meliputi pengolahan data awal, seleksi fitur, pembentukan label kondisi operasi (normal dan *Plugging*), serta pengujian model menggunakan algoritma *Random Forest Classifier*. Kinerja model dievaluasi menggunakan metrik akurasi, precision, recall, F1-score, dan cross-validation. Hasil pengujian menunjukkan bahwa model *Random Forest Classifier* mampu mengklasifikasikan kondisi *Plugging* dengan tingkat akurasi yang tinggi dan stabil, sehingga efektif digunakan sebagai alat bantu dalam sistem pemeliharaan prediktif. Dengan adanya sistem ini, diharapkan operator dapat melakukan tindakan preventif lebih awal untuk meminimalkan gangguan operasi dan meningkatkan keandalan sistem pembangkitan listrik.

Kata Kunci: *Random Forest Classifier, Plugging Pulverizer, PLTU Indramayu, Machine Learning, Pemeliharaan Prediktif*

1. PENDAHULUAN

Transformasi energi yang dipicu oleh fenomena 3D (*Decarbonization, Decentralization, dan Digitalization*) mendorong peningkatan pemanfaatan data operasional dalam sistem pembangkitan listrik. Dalam era Industri 4.0, *Machine Learning* (ML) menjadi teknologi yang semakin penting untuk mendukung analisis data berskala besar, prediksi gangguan peralatan, serta pengambilan keputusan operasional yang lebih cepat, akurat, dan berbasis data (*data-driven decision making*).

PLTU Indramayu berkapasitas 330 MW menggunakan batubara sebagai bahan bakar utama, yang dalam proses pembangkitan harus terlebih dahulu digiling menggunakan *Pulverizer (Coal Mill)* hingga menjadi serbuk halus sebelum dialirkan ke ruang bakar. Keandalan *Coal Mill* memiliki peran yang sangat krusial terhadap kontinuitas operasi pembangkit, karena gangguan pada subsistem ini dapat menyebabkan penurunan daya, *derating* unit, hingga kehilangan output pembangkitan secara signifikan [1].

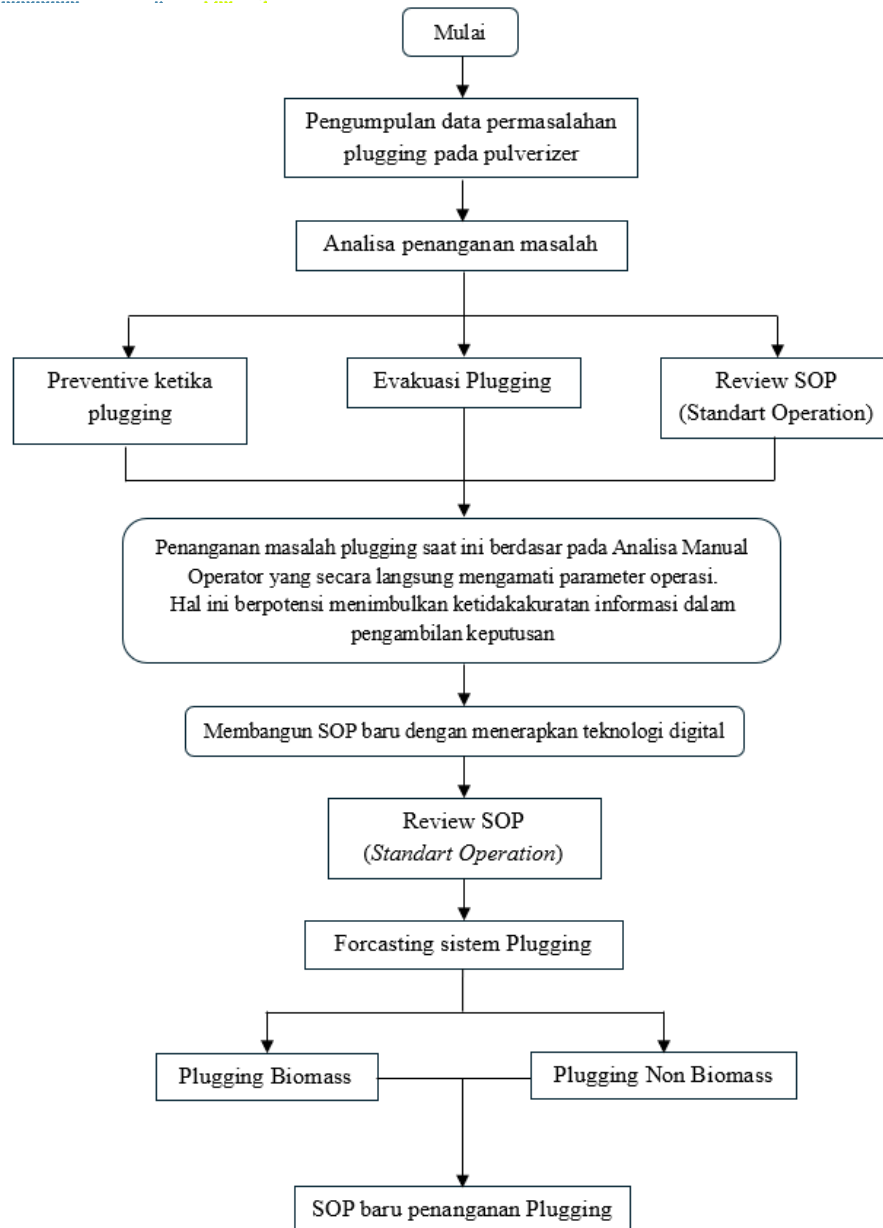
Dalam tiga tahun terakhir, penggunaan *Medium Rank Coal* (MRC) di PLTU Indramayu mengalami penurunan dan secara bertahap digantikan oleh *Low Rank Coal* (LRC). Selain itu, diterapkannya kebijakan bauran biomassa (*co-firing*) sesuai dengan Permen ESDM Nomor 12 Tahun 2023 turut mengubah karakteristik bahan bakar yang digunakan. Perubahan ini berdampak pada meningkatnya risiko terjadinya *Plugging*, yaitu kondisi penyumbatan aliran batubara dan biomassa di dalam sistem *Pulverizer*. *Plugging* umumnya disebabkan oleh kondisi bahan bakar yang basah dan tidak homogen, tekanan kerja *Grinding Roller* yang tidak optimal, serta suplai udara pendorong (*Primary Air*) yang lemah, sehingga material tidak dapat tertransportasi dengan baik menuju ruang bakar.

Berdasarkan data *Pareto Loss Output* tahun 2024, gangguan pada *Coal Mill*, termasuk kejadian *Plugging*, menjadi salah satu kontributor utama kehilangan output pembangkit dan menyumbang nilai *Equivalent Forced Outage Rate* (EFOR) sebesar 1,07%. Kondisi ini menunjukkan perlunya pendekatan yang lebih proaktif dan berbasis data dalam mendeteksi potensi gangguan sejak dini.

Oleh karena itu, diperlukan pengembangan sistem prediksi dini (*early warning system*) berbasis *Machine Learning* untuk meningkatkan keandalan operasi *Pulverizer*. Penelitian ini mengusulkan pengembangan model klasifikasi menggunakan algoritma *Random Forest* yang dikombinasikan dengan metode *Synthetic Minority Over-sampling Technique* (SMOTE) guna mengatasi ketidakseimbangan data. Model ini diharapkan mampu mendeteksi potensi *Plugging* secara akurat dan mendukung strategi pemeliharaan prediktif (*predictive maintenance*) pada sistem *Pulverizer* di PLTU Indramayu.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis *Machine Learning* untuk memprediksi kejadian *Plugging* pada *coal mill*. Alur penelitian secara umum ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

Data yang digunakan berasal dari data historis operasi *coal mill* tahun 2024 dengan parameter utama meliputi *outlet temperature*, *motor current*, *coal mill flow*, *inlet temperature*, dan *mixing flow*. Prototype sistem prediksi *Plugging* dibangun menggunakan data operasional *Coal Mill* yang meliputi temperatur, arus motor, dan aliran batubara. Data diproses melalui tahap *preprocessing*, pelabelan kondisi *Plugging*, serta pemisahan data latih dan uji dengan rasio 70:30. Model dikembangkan menggunakan algoritma *Random Forest Classifier* dan dievaluasi berdasarkan nilai akurasi, *recall*, dan *F1-score*. Hasil evaluasi dimanfaatkan sebagai dasar evaluasi sistem serta perumusan usulan SOP penanganan *Plugging*.

2.1. Pembangkit Listrik Tenaga Uap

Pembangkit Listrik Tenaga Uap (PLTU) merupakan jenis pembangkit yang paling banyak digunakan di Indonesia untuk menghasilkan energi listrik dalam skala besar dan beroperasi berdasarkan siklus *Rankine*, di mana energi panas hasil pembakaran batubara dimanfaatkan untuk menghasilkan uap bertekanan tinggi yang menggerakkan turbin uap dan generator [2]. Batubara dipilih sebagai bahan bakar utama karena ketersediaannya yang melimpah dan biaya produksi yang relatif rendah, meskipun variasi karakteristiknya, seperti kadar air, sulfur, dan abu, berpengaruh terhadap efisiensi pembakaran serta kinerja peralatan pembangkit, khususnya *Pulverizer* dan *Boiler* [3]. Dalam sistem PLTU batubara, *Pulverizer* berperan penting dalam menggiling batubara menjadi serbuk halus guna menjamin pembakaran optimal, dengan tingkat kehalusan yang direkomendasikan mencapai minimal 70% lolos ayakan 200 *mesh* sesuai SPLN K7.004-1:2021 [1]. Di sisi lain, tantangan lingkungan akibat emisi gas rumah kaca mendorong penerapan *co-firing* biomassa melalui Permen ESDM No. 12 Tahun 2023 sebagai bagian dari transisi energi. Seiring perkembangan teknologi digital, pemanfaatan sistem pemantauan berbasis sensor dan *Machine Learning* memungkinkan prediksi dini gangguan operasional, seperti *Plugging* pada *Pulverizer*, sehingga dapat meningkatkan efisiensi, keandalan, dan keberlanjutan operasional PLTU [4].

2.2. Pulverizer pada PLTU

Pulverizer merupakan komponen utama pada sistem pembakaran PLTU berbahan bakar batubara yang berfungsi menghaluskan batubara menjadi partikel kecil agar luas permukaan meningkat dan pembakaran berlangsung lebih efisien [5].

2.3. Plugging

Plugging merupakan fenomena penyumbatan aliran batubara pada sistem penyaluran bahan bakar, seperti *Pulverizer*, *coal feeder*, atau saluran udara primer. Kondisi ini disebabkan oleh kelembaban tinggi, ukuran partikel tidak seragam, kecepatan udara rendah, atau akumulasi material, yang dapat menurunkan efisiensi pembakaran, mengganggu suplai batubara, hingga memicu *shutdown* unit pembangkit [6].

2.4. Machine Learning

Machine Learning (ML) merupakan cabang kecerdasan buatan yang memungkinkan sistem komputer belajar dari data untuk mengenali pola dan membuat prediksi atau klasifikasi tanpa pemrograman eksplisit. Teknologi ini banyak diterapkan di berbagai sektor karena kemampuannya mengolah data dalam jumlah besar secara otomatis [7].

2.5. Random Forest

Algoritma *Random Forest* merupakan metode *ensemble learning* yang menggabungkan banyak *decision tree* untuk tugas klasifikasi atau regresi. Model ini menggunakan teknik *bagging* dan pemilihan fitur secara acak pada setiap

percabangan untuk mengurangi varian. Prediksi akhir ditentukan melalui voting mayoritas atau nilai rata-rata, sehingga menghasilkan model yang lebih akurat dan stabil [5].

3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil perancangan dan implementasi sistem prediksi *Plugging* pada *Pulverizer* PLTU Indramayu menggunakan *Random Forest Classifier*. Pembahasan meliputi gambaran umum data operasi, tahapan pengolahan data, pemilihan fitur, pembentukan model prediksi, hingga evaluasi performa model. Analisis dilakukan terhadap tiga kondisi operasi berbeda untuk memahami pola perubahan parameter sebelum terjadinya *Plugging*, sehingga dapat diimplementasikan sebagai *early warning system* yang mendukung pemeliharaan prediktif di PLTU Indramayu.

3.1. Gambaran Umum

Data yang digunakan dalam penelitian ini diperoleh dari hasil pencatatan proses operasi *Coal mill* 1F di PLTU Indramayu yang merupakan salah satu unit *Pulverizer* pada sistem pembangkitan listrik tenaga uap berkapasitas 3×330 MW. Dalam penelitian ini, data yang digunakan bersumber dari *Distributed Control System* (DCS) Foxboro melalui sistem AIM*Historian, yang merekam parameter proses secara otomatis dengan interval pencatatan setiap 1 menit. Pengambilan data difokuskan pada periode Tahun 2025, yang meliputi beberapa peristiwa aktual terjadinya *Plugging* pada *Coal mill* 1B. Untuk mendapatkan hasil analisis yang komprehensif, data penelitian dibagi menjadi tiga kategori kondisi operasi, yaitu: Kondisi 1 — *Plugging* dengan campuran *sawdust* (*co-firing*), Kondisi 2 — operasi normal dengan campuran *sawdust*, Kondisi 3 — operasi normal dengan batubara murni. Total data yang digunakan berjumlah 181 baris data dengan rentang waktu 06/11/2025 16:00:00 sampai 06/11/2025 19:00:00 dengan interval data 1 menit. Parameter yang digunakan meliputi *Coal feeder E Flow*, *Mill E Motor current*, *Mix Air Flow Entering Pulverizer E*, *Pulverizer E Inlet Temperature*, *Pulverizer E Primary Air Flow*, *Pulverizer E Primary Air Pressure*, *Pulverizer E Primary Air Temperature*, *Pulverizer E Outlet Air and Coal Mixture Temperature*, *Pulverizer E Outlet Air Coal Mixture Temperature*, serta *Air Fuel Ratio (AFR)*.

3.2. Pembahasan

Dua parameter utama, yaitu Air-Fuel Ratio (AFR) dan arus motor *Pulverizer*, digunakan sebagai acuan dalam pengembangan model *Machine Learning* berbasis *Random Forest Classifier*, dengan temperatur outlet *Pulverizer* sebagai parameter pendukung. Seluruh proses diimplementasikan menggunakan bahasa pemrograman Python.

Proses pengembangan model prediksi *Plugging* dimulai dengan inialisasi pustaka Python (Pandas, NumPy, *Random Forest*, SMOTE, Matplotlib) dan pemuatan dataset historis kejadian *Plugging Pulverizer* 1B dari file Excel ke dalam dataframe, kemudian dilakukan standarisasi penamaan atribut serta pembentukan

parameter turunan AFR dan DP dengan menetapkan kolom waktu sebagai indeks temporal sesuai Gambar 2.

```
df = pd.read_excel('/1B Plugging Dalam Mill.xlsx')
```

Gambar 2. Pengolahan dan standarisasi dataset historis

Tahap eksplorasi data dilakukan melalui visualisasi tren berbasis waktu untuk mengidentifikasi pola operasi dan anomali, serta analisis statistik deskriptif untuk memahami karakteristik dan rentang nilai normal setiap parameter. Pelabelan kondisi *Plugging* kemudian diterapkan secara rule-based berdasarkan kombinasi *threshold parameter* MIL, MOT, AFR, dan DP sesuai Gambar 3.

```
# Ganti nama kolom sesuai mapping
df.rename(columns=column_mapping, inplace=True)

# Hitung AFR = Mix Air Flow / Coal Flow
df['AFR'] = df['MXF'] / df['CLF']

# Hitung DP = Mix air Press inlet - Mix air Press Outlet
df['DP'] = df['PAPIN'] - df['PAPOUT']

# Jadikan tanggal_penarikan sebagai index
df.set_index('tanggal_penarikan', inplace=True)

df
```

Gambar 3. Pelabelan Kondisi *Plugging* Berbasis Aturan Operasi *Pulverizer*

Kemudian dilanjutkan dengan penambahan fitur lag hingga 20 interval waktu untuk menangkap dinamika temporal kejadian *Plugging*. Variabel target prediksi dibentuk melalui pergeseran label berbasis waktu untuk mendeteksi *Plugging* 30 menit ke depan sesuai Gambar 4, lalu dataset dibagi dengan rasio 80:20 untuk pelatihan dan pengujian model *Random Forest* yang dikonfigurasi dengan teknik penanganan ketidakseimbangan kelas dan pencegahan *overfitting*.

```
# Membuat kolom plugging_label sesuai dengan kondisi yang diinginkan
df['plugging_label'] = (((df['MIL'] > 38) &
    # 31.99 Aumsi 75% data biomass
    (df['MOT'] < 58)) |
    # 59 MOT asumsi data biomass
    ((df['MIL'] > 38) | (df['AFR'] < 1.6) | (df['DP'] > 4.2))).astype(int)
    # 31.99 Aumsi 75% data biomass
    # AFR 1.8 Asumsi biomass basah

# Tampilkan hasil
df
```

Gambar 4. Pembentukan Target Prediksi *Plugging* 30 menit kedepan

Tahap akhir meliputi evaluasi komprehensif performa model menggunakan beberapa metrik evaluasi yaitu akurasi keseluruhan, *classification report* yang mencakup *precision*, *recall*, dan *f1-score* untuk setiap kelas, serta *cross-validation* untuk memastikan konsistensi dan generalisasi model. Penjelasan konseptual terkait penerapan fitur lag dan dampaknya terhadap prediksi disajikan secara deskriptif tanpa menampilkan potongan kode Gambar 5.

```
# Membuat DataFrame baru untuk menyimpan kolom Lag
lags = {}

# Menambahkan kolom Lag untuk setiap variabel
for lag in range(1, 21):
    lags[f'CLF_lag_{lag}'] = df['CLF'].shift(lag)
    lags[f'MIL_lag_{lag}'] = df['MIL'].shift(lag)
    lags[f'MXF_lag_{lag}'] = df['MXF'].shift(lag)
    lags[f'MOT_lag_{lag}'] = df['MOT'].shift(lag)
    lags[f'AFR_lag_{lag}'] = df['AFR'].shift(lag)
    lags[f'DP_lag_{lag}'] = df['DP'].shift(lag)

# Menggabungkan semua kolom Lag ke dalam DataFrame df secara bersamaan
df = pd.concat([df, pd.DataFrame(lags)], axis=1)

# Menghapus baris dengan NaN akibat proses lagging
df = df.dropna().reset_index(drop=True)
df
```

Gambar 5. Penambahan Fitur Lag Temporal Sebelum Dilakukan Pelatihan Dan Evaluasi Model *Random Forest*

3.3. Hasil dan Evaluasi Model

Evaluasi model dilakukan untuk menilai kemampuan *Random Forest Classifier* dalam memprediksi potensi terjadinya *Plugging* pada *Pulverizer* berdasarkan parameter operasi serta fitur berbasis waktu yang telah dibentuk. Hasil evaluasi dirangkum dalam Gambar 6 yang mencakup metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *cross-validation* sebagai indikator performa dan kestabilan model. Berdasarkan Gambar 6, evaluasi akurasi menunjukkan bahwa model *Random Forest Classifier* menghasilkan nilai akurasi sebesar 0,93, yang berarti 93% data uji berhasil diklasifikasikan dengan benar. Nilai ini mengindikasikan bahwa model memiliki kemampuan yang baik dalam membedakan kondisi operasi normal dan kondisi *plugging* pada *pulverizer*, serta mencerminkan bahwa pola hubungan antara parameter operasi *pulverizer* dan kejadian *plugging* telah dipelajari secara efektif oleh model.

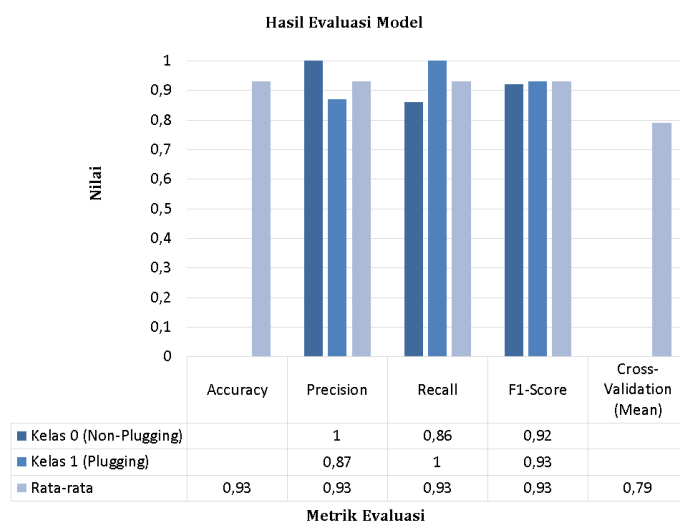
Evaluasi *precision* yang tertera pada Gambar 6 menunjukkan model menghasilkan nilai *precision* sebesar 1,00 pada kelas *non-plugging* dan 0,87 pada kelas *plugging*. Nilai *precision* yang sangat tinggi pada kelas *non-plugging* menunjukkan bahwa seluruh prediksi operasi normal yang dihasilkan oleh model bersifat tepat, sementara nilai *precision* pada kelas *plugging* menunjukkan bahwa sebagian besar prediksi *plugging* yang dihasilkan oleh model sesuai dengan

kondisi aktual, sehingga model mampu meminimalkan kesalahan peringatan palsu dengan baik.

Dari segi *recall* sebagaimana ditampilkan pada Gambar 6, model menghasilkan nilai *recall* sebesar 0,86 pada kelas *non-plugging* dan 1,00 pada kelas *plugging*. Nilai *recall* sebesar 1,00 pada kelas *plugging* menunjukkan bahwa seluruh kejadian *plugging* pada data uji berhasil terdeteksi oleh model tanpa adanya kejadian yang terlewatkan, yang mengindikasikan bahwa model memiliki tingkat sensitivitas yang sangat tinggi terhadap kondisi *plugging* dan mampu meminimalkan kesalahan *false negative* secara efektif.

Hasil evaluasi *F1-score* pada Gambar 6 menunjukkan nilai sebesar 0,92 pada kelas *non-plugging* dan 0,93 pada kelas *plugging*. Nilai *F1-score* yang tinggi pada kedua kelas ini menunjukkan bahwa model memiliki keseimbangan yang baik antara *precision* dan *recall*. Secara khusus, nilai *F1-score* pada kelas *plugging* mengindikasikan bahwa model mampu mendeteksi sebagian besar kejadian *plugging* dengan tingkat ketepatan yang memadai, sehingga memberikan penilaian performa yang representatif terhadap kemampuan prediksi model.

Terakhir, berdasarkan hasil *cross-validation* yang tercantum pada Gambar 6, model memperoleh nilai *mean cross-validation score* sebesar 0,79. Nilai ini menunjukkan bahwa secara rata-rata model mampu mempertahankan tingkat kinerja yang cukup baik ketika diuji pada subset data yang berbeda menggunakan metode *5-fold cross-validation*. Meskipun terdapat variasi nilai skor antar lipatan yang mencerminkan karakteristik data operasi *pulverizer* yang dinamis, nilai *mean cross-validation* yang diperoleh mengindikasikan bahwa model memiliki kemampuan generalisasi yang memadai dan tidak mengalami *overfitting* yang signifikan terhadap data pelatihan. Dengan demikian, hasil evaluasi secara keseluruhan memperkuat kesimpulan bahwa model *Random Forest* yang dikembangkan memiliki kestabilan performa yang cukup baik dan layak digunakan untuk memprediksi potensi *plugging* pada *pulverizer* dalam kondisi operasional yang bervariasi.



Gambar 6. Grafik Hasil Evaluasi Model

4. SIMPULAN

Berdasarkan hasil perancangan, implementasi, serta evaluasi sistem prediksi *Plugging* pada *Pulverizer* PLTU Indramayu, dapat disimpulkan bahwa *Plugging* memiliki keterkaitan kuat dengan perubahan pola parameter operasi, terutama pada kondisi *co-firing* biomassa. Parameter *Air Fuel Ratio* (AFR) dan arus motor *Pulverizer* menunjukkan perubahan signifikan sebelum terjadinya *Plugging* sehingga layak dijadikan indikator utama prediksi. *Random Forest Classifier* berhasil diterapkan menggunakan data historis dari DCS Foxboro dan mampu mempelajari hubungan non-linear antar parameter secara efektif. Penambahan fitur lag berbasis waktu dan target prediksi 30 menit ke depan menjadikan model bersifat prediktif dan mendukung pemeliharaan prediktif.

Evaluasi model menunjukkan performa sangat baik dengan accuracy 0,93 yang mampu mengklasifikasikan 93% data uji secara benar. *Precision* sebesar 1,00 (*non-Plugging*) dan 0,87 (*Plugging*) menunjukkan ketepatan tinggi dalam meminimalkan peringatan palsu. *Recall* sebesar 0,86 (*non-Plugging*) dan 1,00 (*Plugging*) membuktikan seluruh kejadian *Plugging* berhasil terdeteksi tanpa terlewat. *F1-score* sebesar 0,92 (*non-Plugging*) dan 0,93 (*Plugging*) menunjukkan keseimbangan baik antara *precision* dan *recall*. *Mean cross-validation* sebesar 0,79 mengindikasikan kemampuan generalisasi yang baik dan model tidak mengalami *overfitting* signifikan meskipun data dinamis. Secara keseluruhan, sistem prediksi ini layak digunakan sebagai *early warning system* karena mampu memberikan peringatan dini terhadap potensi *Plugging* dengan akurasi dan keandalan tinggi serta berpotensi meningkatkan *reliability* sistem *Pulverizer* di PLTU Indramayu.

DAFTAR PUSTAKA

- [1] Kementerian Energi dan Sumber Daya Mineral Republik Indonesia, "Standar Perusahaan Listrik Negara (SPLN) K7.004-1: Sistem Pemeliharaan Pembangkit Tenaga Listrik", Jakarta, Indonesia, 2021.
- [2] Samsudin, A., Pratama, R., and Hidayat, M., "Analisis Sistem Pembangkitan Listrik Tenaga Uap Berbasis Batubara", *Jurnal Teknik Mesin*, Vol. 11, No. 2, pp. 85–94, 2019.
- [3] M. Mercangoez dan J. Poland, "Dynamic modeling and simulation of vertical spindle coal mills", *Applied Energy*, vol. 88, no. 4, pp. 1231–1241, 2011.
- [4] R. Noviali, A. K. Hadi, B. J. Santoso, H. Budiono, J. Dian, dan Andri, "Analisis gangguan plugging pulverizer pada PLTU berbasis data operasional", *Jurnal Teknik Energi dan Pembangkitan*, 2023.
- [5] Anthony, M. B., "Analisis Coal *Plugging* atau Penyumbatan Batu Bara pada Mesin Coal Feeder Unit 1–4 dengan Metode Fault Tree Analysis (FTA)", *JATI UNIK: Jurnal Ilmiah Teknik Industri*, Vol. 3, No. 2, pp. 65–73, 2020.
- [6] Roihan, A., Sutanto, T., and Gunawan, R., "Penerapan *Machine Learning* untuk Klasifikasi dan Prediksi Data Industri", *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, Vol. 4, No. 1, pp. 21–28, 2020.
- [7] Breiman, L., "*Random Forests*", *Machine Learning*, Vol. 45, No. 1, pp. 5–32, 2001.