

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai *Implementasi Sistem Peringatan Dini Untuk Predictive Maintenance Pada Mesin Eye Forming Robot Menggunakan Random Forest dan Notifikasi WhatsApp API Secara Real Time*, dapat disimpulkan bahwa:

1. Penelitian ini menggunakan beberapa variasi metode Random Forest untuk mengklasifikasikan jenis kerusakan pada mesin. Metode yang digunakan meliputi:
 - Random Forest klasik (baseline) : Sebagai dasar perbandingan performa model
 - Hyperparameter Tuning : Optimasi parameter untuk meningkatkan akurasi model
 - SMOTE (Synthetic Minority Over Sampling Technique) : Penanganan ketidakseimbangan data
 - Ensemble Voting : Kombinasi prediksi dari multiple model
 - Stratified K-Fold Cross Validation : Validasi model yang lebih robust

Implementasi variasi metode ini menunjukkan pendekatan yang komprehensif dalam mengoptimalkan performa model machine learning untuk keperluan predictive maintenance.

2. Dari seluruh metode yang diuji, model Random Forest dengan teknik SMOTE memberikan performa terbaik dengan akurasi tertinggi sebesar 73,33%, dibandingkan dengan metode lainnya. Hal ini menunjukkan bahwa teknik balancing data dengan SMOTE dapat meningkatkan kemampuan model dalam memprediksi kelas minoritas, terutama dalam kondisi data yang tidak seimbang.
3. Hasil evaluasi model menunjukkan bahwa Confusion Matrix untuk model RF+SMOTE memberikan klasifikasi yang lebih akurat dan seimbang di semua kelas, terutama dalam membedakan antara kelas Motion Fault dan Drive Fault yang sebelumnya banyak mengalami misklasifikasi.
4. Tingkat akurasi sebesar 73,33% menunjukkan bahwa model memiliki kemampuan yang cukup baik untuk memprediksi kondisi maintenance pada mesin Eye Forming Robot, meskipun masih terdapat ruang untuk peningkatan akurasi di masa mendatang.
5. Beberapa faktor yang memengaruhi ketidaktepatan prediksi antara lain: Keterbatasan Data, Masalah Regulasi Model, Variabilitas Operasional.
6. Berdasarkan data utility mesin yang diamati selama bulan Mei dan Juni 2025, terdapat perbedaan tingkat breakdown yang menggambarkan efektivitas proses maintenance.
 - Pada bulan Mei 2025, persentase waktu breakdown mencapai **7,77%**
 - Sementara itu, pada bulan Juni 2025, persentase breakdown menurun menjadi **6,8%**. Penurunan ini menunjukkan adanya peningkatan efisiensi sistem dan perbaikan kondisi mesin, yang sejalan dengan tujuan dari implementasi sistem predictive maintenance berbasis machine learning.

Fakta ini memperkuat bahwa sistem prediksi kerusakan yang dibangun mampu memberikan kontribusi nyata terhadap pengurangan waktu kerusakan mesin.

Keluaran dari sistem prediksi *maintenance* pada mesin Eye Forming Robot divisualisasikan dengan *Confusion Matrix*. Visualisasi dari *Confusion Matrix* menunjukkan bahwa ada beberapa kondisi dimana hasil klasifikasi sesuai dengan data aktual dan tidak sesuai. Kondisi ini dapat disebabkan beberapa faktor antara lain:

1. Keterbatasan Data: Jumlah data yang kurang cukup luas dapat mempengaruhi kemampuan model dalam mengenali pola yang kompleks
2. Masalah Regulasi: Terlalu banyak atau sedikit regulasi yang diterapkan pada model sehingga menyebabkan *underfitting* atau *overfitting*
3. Variabilitas Kondisi Operasional: Perbedaan kondisi lingkungan dan operasional mesin yang dapat mempengaruhi performa prediksi

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, berikut adalah beberapa saran yang dapat dipertimbangkan untuk pengembangan ke depan:

1. Penambahan Jumlah dan Variasi Data : Pengumpulan data yang lebih luas dan beragam untuk meningkatkan volume dan representasi data. Ini dapat mencakup pengumpulan data dari periode waktu yang lebih panjang, kondisi operasional yang berbeda, dan variasi jenis kerusakan yang lebih banyak. Data yang lebih komprehensif akan membantu model belajar pola yang lebih kompleks dan meningkatkan kemampuan generalisasinya.

2. Pengujian Model Lanjutan: Pengujian kinerja model Random Forest dengan algoritma *machine learning* canggih lainnya, seperti *Gradient Boosting* (*XGBoost*, *LightGBM*), *Support Vector Machines* (*SVM*), atau bahkan model *Deep Learning* jika data tersedia dalam jumlah besar dan kompleksitas yang memadai. Penjelajahan teknik *ensemble* yang lebih kompleks juga bisa dipertimbangkan.
3. Optimasi *Hyperparameter* yang Lebih Mendalam: Manfaatkan teknik optimasi *hyperparameter* yang lebih canggih, seperti *Grid Search*, *Random Search*, atau *Bayesian Optimization*, untuk menemukan kombinasi *hyperparameter* yang optimal. Ini dapat lebih memaksimalkan akurasi model dan membantu mencegah *underfitting* atau *overfitting*.
4. Pengembangan Sistem Notifikasi yang Lebih Kuat: Perluas fungsionalitas sistem notifikasi WhatsApp API untuk menyertakan informasi yang lebih rinci tentang prediksi kerusakan, tingkat keparahan, atau rekomendasi tindakan pemeliharaan awal. Pertimbangkan juga integrasi dengan sistem manajemen pemeliharaan yang sudah ada untuk mengotomatiskan alur kerja.
5. Analisis *Root Cause* Otomatis: Kembangkan kapabilitas model untuk tidak hanya memprediksi jenis kerusakan, tetapi juga memberikan indikasi tentang kemungkinan penyebab utama (*root cause*) dari kerusakan tersebut. Ini akan sangat membantu teknisi dalam mendiagnosis masalah dengan lebih cepat dan efisien.