

## BAB V

### PENUTUP

Pada bab ini, disajikan kesimpulan dari hasil penelitian peneliti yang telah dilakukan serta saran untuk penelitian selanjutnya dan penerapannya di industri. Bab ini bertujuan untuk merangkum temuan utama dari penelitian serta memberikan rekomendasi untuk pengembangan di masa depan.

#### 5.1. Kesimpulan

Penelitian ini bertujuan untuk mengembangkan model *Predictive Maintenance* dengan menggunakan *Random Forest* yang dioptimasi dengan *Random Search* dan pendekatan *One-vs-Rest* untuk *Multiclass Classification*, dalam rangka memprediksi kegagalan mesin pada dataset sensor kendaraan. Berdasarkan pengujian yang dilakukan, dapat disimpulkan beberapa hal berikut:

1. *Optimalisasi Model Menggunakan Random Search.* Optimasi *hyperparameter* menggunakan *Random Search* pada model *Random Forest* memberikan peningkatan signifikan dalam hal akurasi dan performa keseluruhan model. Penggunaan parameter yang lebih tepat seperti *n\_estimators*, *max\_depth*, *min\_samples\_split*, dan *min\_samples\_leaf* menghasilkan model yang lebih robust dan dapat menangani data dengan lebih baik. Hasil terbaik diperoleh pada model yang menggunakan *Random Search* dibandingkan dengan model yang hanya menggunakan parameter *default*. Peningkatan performa ini terlihat pada metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *f1-score*, khususnya pada kelas-kelas kegagalan yang lebih sulit diprediksi.
2. *Pendekatan One-vs-Rest untuk Multiclass Classification.* Penggunaan pendekatan *One-vs-Rest* terbukti efektif dalam mengatasi masalah klasifikasi multi-kelas, terutama ketika ada ketidakseimbangan data antara kelas mayoritas (*No Failure*) dan kelas-kelas kegagalan lainnya. Pendekatan ini memungkinkan model untuk lebih fokus pada klasifikasi setiap jenis kegagalan secara terpisah, menghasilkan prediksi yang lebih akurat untuk masing-masing kelas.

3. Evaluasi Model. Berdasarkan hasil evaluasi model dengan metrik seperti ROC AUC, *Matthews Correlation Coefficient* (MCC), *precision*, *recall*, dan *f1-score*, model yang dioptimasi mampu mencapai accuracy yang tinggi dan dapat memprediksi kegagalan mesin dengan tingkat keandalan yang cukup baik. Terutama, model ini menunjukkan kemampuan yang lebih baik dalam memprediksi kelas kegagalan meskipun ada ketidakseimbangan data.
4. Kontribusi Penelitian. Penelitian ini memberikan kontribusi signifikan dalam bidang *Predictive Maintenance* dengan memanfaatkan algoritma *machine learning*, khususnya *Random Forest*, yang telah terbukti efektif dalam menangani data kompleks. Dengan optimasi *hyperparameter* dan pendekatan klasifikasi yang tepat, penelitian ini dapat diaplikasikan untuk meningkatkan efisiensi operasional di berbagai sektor industri yang bergantung pada kendaraan atau mesin berat.

## 5.2. Saran

Berdasarkan hasil penelitian yang telah dilakukan, berikut beberapa saran yang dapat dikaji untuk penelitian di masa depan dan penerapan model di industri:

1. Penggunaan Dataset yang lebih Variatif. Penelitian ini menggunakan dataset AI4I 2020 yang bersifat sintesis, sehingga hasil yang diperoleh lebih bergantung pada karakteristik data tersebut. Untuk meningkatkan validitas dan generalisasi model, disarankan untuk menggunakan dataset yang lebih bervariasi dan representatif dari berbagai kondisi operasional nyata yang ada di industri. Data yang mencakup faktor-faktor eksternal, seperti kondisi lingkungan atau faktor operasional lainnya, dapat memberikan pemahaman yang lebih menyeluruh mengenai kinerja model di dunia lapangan.
2. Integrasi dengan Sistem IoT dan *Monitoring Real-Time*. Meskipun model yang dikembangkan dalam penelitian ini menunjukkan performa yang baik, implementasi sistem *Predictive Maintenance* yang sebenarnya di lapangan akan sangat bergantung pada integrasi model dengan sistem *Internet of Things (IoT)* dan monitoring real-time. Oleh karena itu, penelitian selanjutnya dapat mencakup integrasi model dengan perangkat keras IoT

untuk pemantauan kondisi mesin secara langsung dan penerapan perbaikan yang lebih tepat waktu.

3. Eksplorasi Metode Lain untuk Mengatasi Ketidakseimbangan Data. Walaupun pendekatan One-vs-Rest efektif dalam mengatasi klasifikasi multi-kelas, ada baiknya untuk mengeksplorasi metode lain yang dapat lebih optimal dalam menangani masalah ketidakseimbangan data, seperti SMOTE (*Synthetic Minority Over-sampling Technique*) atau *Cost-sensitive learning*. Pendekatan ini dapat meningkatkan prediksi pada kelas-kelas minoritas yang sulit diprediksi, seperti Tool Wear Failure atau Random Failure.
4. Pengujian dengan Algoritma Lain. Meskipun *Random Forest* terbukti efektif dalam penelitian ini, pengujian dengan algoritma lain seperti *XGBoost*, *Support Vector Machine (SVM)*, atau *Neural Networks* dapat dilakukan untuk membandingkan kinerja dan efektivitas model dalam konteks *Predictive Maintenance*. Pendekatan ini dapat memberikan wawasan tambahan mengenai kelebihan dan kelemahan masing-masing algoritma dalam menangani masalah klasifikasi multi-kelas pada data sensor.
5. Optimasi Lebih Lanjut dengan Teknik *Ensemble* Lainnya. Untuk lebih meningkatkan performa model, disarankan untuk menerapkan teknik-teknik ensemble lainnya, seperti *Boosting* atau *Bagging* yang dapat memperkuat kemampuan model dalam menghasilkan prediksi yang lebih stabil dan akurat, terutama ketika dihadapkan pada data yang sangat bervariasi dan tidak seimbang.