

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan seluruh proses analisis, pengujian, dan evaluasi model terhadap 19 percobaan algoritma *Machine Learning* yang mencakup metode *unsupervised*, *supervised* dan pendekatan *hybrid* untuk mendeteksi anomali pada data sensor mesin, arsitektur model yang terbukti paling efektif untuk kasus deteksi anomali ini adalah pendekatan *Hybrid* yang menggabungkan kekuatan metode *Unsupervised* dan *Supervised*. Model ini dirancang untuk memanfaatkan kemampuan *Unsupervised Learning* dalam menemukan pola data yang menyimpang dan tidak seimbang, yang kemudian diperkuat oleh algoritma *Supervised* dalam klasifikasi akhir.

Penentuan algoritma terbaik didasarkan pada perbandingan komprehensif metrik evaluasi F1-score, *Precision*, *Recall*, PR AUC, dan *Confidence Interval* (CI) 95% dari seluruh konfigurasi model yang diuji. Dalam kategori *Unsupervised Learning*, model Autoencoder (AE) menunjukkan *Recall* tertinggi sebesar 0.8089. Hal ini menandakan bahwa AE memiliki kemampuan paling efektif dalam menangkap insiden anomali yang terjadi pada data sensor meskipun *Precision*-nya masih rendah (0.0945) dan PR AUC-nya hanya 0.0959. Sementara itu, XGBoost ditetapkan sebagai model supervised murni terbaik dengan F1-score 0.7932. Model ini menawarkan stabilitas dan akurasi tinggi dengan nilai *Precision* 0.8246 dan *Recall* 0.7642. Kinerja optimal XGBoost ditegaskan oleh PR AUC 0.8151 dengan CI 95% (0.7734, 0.8604) yang solid, menunjukkan konsistensi dan daya diskriminasi yang andal.

Namun, performa terbaik secara keseluruhan dicapai oleh model *Hybrid Isolation Forest + XGBoost*. Model *hybrid* ini menghasilkan F1-score tertinggi 0.8456, didukung oleh *Precision* 0.8939 dan *Recall* 0.8022. Model ini tidak hanya memberikan keseimbangan terbaik antara *Precision* dan *Recall*, tetapi juga mencetak PR AUC tertinggi 0.8519 di seluruh percobaan. *Confidence*

Interval (0.8127, 0.8888) yang sempit membuktikan bahwa estimasi kinerja model ini sangat stabil dan memiliki variabilitas yang rendah, menjadikannya pilihan paling robust untuk deteksi anomali pada data time series.

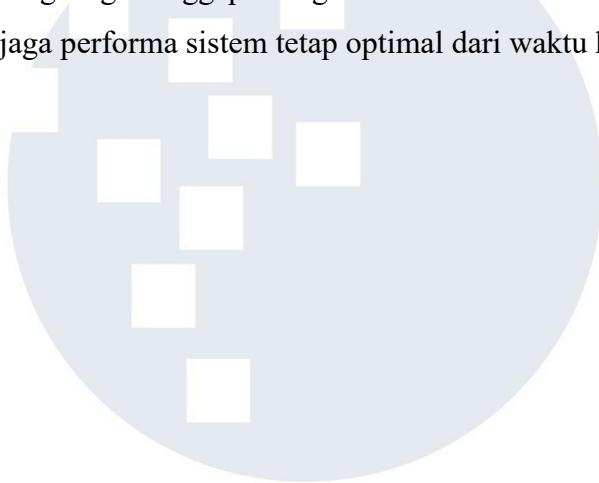
Peningkatan kinerja model secara keseluruhan dicapai melalui dua strategi penting. Pertama, adanya parameter tuning yang optimal pada setiap algoritma, seperti mengatur kedalaman dan jumlah estimator pada XGBoost, untuk memaksimalkan kemampuan prediksi. Kedua, penggunaan teknik SMOTE (*Synthetic Minority Over-sampling Technique*) terbukti krusial karena berhasil secara signifikan meningkatkan *Recall*, atau kemampuan model mendeteksi *anomaly* yang mana menjadi metric utama dalam penelitian ini. Penggunaan metode *hybrid unsupervised-supervised* juga dianggap sesuai mengingat bahwa data asli sensor di pabrik memiliki label awal sehingga harus ditentukan telebih dahulu menggunakan metode *unsupervised*.

Secara keseluruhan, penelitian ini berhasil menjawab tujuan proyek untuk mengembangkan model *Machine Learning* yang efektif dalam mendeteksi anomali pada mesin Utility (HVAC). Hasil ini mendukung upaya PT. Saka Farma untuk beralih ke sistem *Predictive Maintenance*, memungkinkan perencanaan pemeliharaan, memfasilitasi pemesanan suku cadang impor lebih awal, dan mengubah kerugian tak terduga menjadi biaya operasional yang dapat direncanakan.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat diberikan untuk pengembangan penelitian dan penerapan model deteksi anomali di lingkungan PT Saka Farma. Pertama, penelitian selanjutnya disarankan menggunakan volume data yang lebih besar misalnya minimal 50.000 baris, mengingat data sensor industri pada umumnya tersedia dalam jumlah puluhan hingga ratusan ribu baris. Ukuran dataset yang lebih besar akan membantu model dalam mempelajari pola operasional mesin secara lebih komprehensif, mengurangi risiko overfitting, serta meningkatkan stabilitas prediksi *anomaly*.

Kedua, implementasi nyata di pabrik sebaiknya dimulai dari pendekatan *unsupervised* atau *hybrid*, karena data sensor asli tidak memiliki label. Dengan demikian, mekanisme *pseudo-labeling* dan *feedback engineer* sangat disarankan untuk dikembangkan sebagai langkah awal menuju model *semi-supervised* yang lebih akurat. Ketiga, Model perlu dilakukan retraining setiap 3 bulan atau setelah terjadi perubahan distribusi sensor dengan mekanisme drift monitoring berbasis *PR AUC* dan *Confidence Interval* agar perubahan yang terjadi karena faktor waktu dan mesin yang dipakai secara instensif tidak langsung dianggap sebagai anomali. Pembaruan model secara rutin akan menjaga performa sistem tetap optimal dari waktu ke waktu.



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA