

BAB I

PENDAHULUAN

1.1 Latar Belakang

Industri sekarang tengah beralih ke arah ekosistem teknologi dan data, dikenal sebagai industri 4.0 (Reis & Gins, 2017). Namun, di tengah transformasi ini, industri masih menghadapi tantangan besar terkait *downtime* yang tidak terduga dan biaya perawatan yang tinggi akibat keterbatasan metode pemeliharaan tradisional. Pendekatan *reactive maintenance* (RM) hanya bertindak setelah terjadi kegagalan sehingga menimbulkan risiko kerusakan tambahan dan biaya reaktif yang besar, sedangkan *preventive maintenance* (PM) sering kali menyebabkan perawatan yang tidak perlu dengan biaya pencegahan yang tinggi (Zhu et al., 2024). Kompleksitas dan fleksibilitas sistem industri modern membuat pendekatan tersebut tidak lagi efektif. Untuk itu, dibutuhkan strategi pemeliharaan yang mampu memperkirakan kegagalan sebelum terjadi, sehingga memungkinkan intervensi yang lebih tepat waktu, efisien, dan hemat biaya. Untuk itu, dibutuhkan strategi pemeliharaan yang lebih cerdas, salah satunya adalah *predictive maintenance* (PdM), yang memanfaatkan teknologi seperti *internet of things* (IoT), *big data*, dan kecerdasan buatan untuk memprediksi kegagalan peralatan sebelum terjadi sehingga memungkinkan intervensi yang tepat waktu, efisien, dan hemat biaya (Pech et al., 2021).

Rendahnya penerapan strategi *predictive maintenance* (PdM) yang efisien di lingkungan produksi masih menjadi sebuah tantangan besar. Kompleksitas implementasi *predictive maintenance* tidak hanya berasal dari kebutuhan akan strategi yang tepat, tetapi juga dari minimnya pemanfaatan algoritma *machine learning* (ML) dalam aplikasi *predictive maintenance*. Dua faktor utama yang menjadi hambatan adalah ketersediaan profesional yang memiliki kompetensi di bidang *machine learning* atau ilmu data dan ketiadaan strategi sebelumnya seperti *reactive maintenance* maupun *preventive maintenance* yang dapat menghasilkan data historis pemeliharaan dan kegagalan peralatan sebagai basis untuk pengembangan *predictive maintenance* (Carvalho et al., 2019). Selain itu, tantangan utama yang masih dihadapi adalah kurangnya solusi yang menggabungkan semua

elemen berbeda dalam satu kerangka kerja atau hanya mempertimbangkan satu aspek saja, misalnya hanya deteksi anomali atau hanya prediksi kegagalan, tanpa mengintegrasikan berbagai metode dalam sistem yang lebih komprehensif. Pendekatan pembelajaran mesin dalam pemeliharaan prediktif juga memiliki keterbatasan, terutama dalam menangani data kategorikal yang beririsian, yang menyebabkan algoritma klasifikasi sering kali mengalami bias, sehingga prediksi yang dihasilkan kurang akurat (Ribeiro, 2017). Selain itu, belum adanya dashboard khusus yang dirancang secara spesifik untuk pemeliharaan prediktif menjadi tantangan lain dalam implementasi di industri. Sebagian besar sistem yang ada masih menggunakan pendekatan manual atau terfragmentasi, yang menyebabkan keterbatasan dalam pemantauan *real-time*, analisis data historis, serta integrasi dengan berbagai sensor dan model *machine learning*.

Untuk mengatasi tantangan dalam sistem *predictive maintenance* yang masih mengandalkan pendekatan *single model*, studi ini mengusulkan pengembangan dashboard interaktif berbasis *machine learning* yang mengintegrasikan tiga model utama, yaitu *extreme gradient boosting* (XGBoost) untuk peramalan, *isolation forest* (iForest) untuk deteksi anomali, dan *random forest* (RF) untuk prediksi kegagalan. Pemilihan ketiga model ini didasarkan penelitian sebelumnya dalam menangani permasalahan spesifik dalam *predictive maintenance*, seperti *extreme gradient boosting* (XGBoost) yang merupakan salah satu algoritma yang banyak digunakan dalam peramalan data deret waktu karena kemampuannya menangani data dengan *noise* tinggi, tanpa tren yang jelas, serta adaptif terhadap nilai hilang dan kesalahan model sebelumnya (Shaik et al., 2024). Karakteristik ini membuat XGBoost efektif dalam sistem *predictive maintenance* berbasis data *real-time*, di mana akurasi prediksi kondisi sangat penting untuk mencegah kegagalan. Sebagai algoritma *ensemble boosting* yang telah dioptimalkan, XGBoost unggul dalam membangun model prediktif yang kuat untuk data kompleks. Jia et al., (2021) menyatakan bahwa model ini memiliki akurasi dan efisiensi terbaik, melampaui model *machine learning* tradisional lainnya, sehingga ideal untuk aplikasi prediktif di bidang pemeliharaan mesin, pemantauan lingkungan, dan optimasi operasional. *Isolation forest* (iForest) dipilih karena merupakan pendekatan *unsupervised learning* yang efektif dan efisien untuk deteksi anomali. Berbeda dari metode

konvensional yang bergantung pada *supervised learning*, iForest bekerja dengan mengisolasi titik data anomali, sehingga sangat cocok untuk dataset besar dan kompleks dengan waktu komputasi yang efisien, karena data anomali yang cenderung sedikit membuat metode isolasi ini sangat efektif dalam mendeteksi *outlier*. Keunggulan ini didukung oleh Feng et al., (2022) dalam deteksi anomali pada data jaringan komputer, yang menunjukkan keunggulan model *isolation forest* dibandingkan *one-class SVM* (OCSVM) dan *local outlier factor* (LOF). Çınar et al., (2020) juga membuktikan bahwa iForest mengungguli algoritma lain seperti *k-nearest neighbors* (KNN), *neural network* (NN), *bernonulli naïve bayes* (BNB), dan *decision tree* (DT), dengan peningkatan akurasi setelah optimasi waktu pelatihan. Secara keseluruhan, *isolation forest* terbukti andal dalam mendeteksi *outlier* secara stabil dan optimal, terutama dalam konteks data sensor industri yang kompleks. *Random forest* (RF) dikenal memiliki efektivitas tinggi dalam prediksi kegagalan, dengan keunggulan seperti kemampuan menangani data berdimensi tinggi, interaksi variabel kompleks, dataset tidak seimbang, serta seleksi fitur otomatis. *Random forest* juga memiliki kecepatan pelatihan yang baik, risiko *overfitting* rendah, dan performa stabil di berbagai kondisi data. Çınar et al., (2020) menunjukkan bahwa *random forest* mencapai akurasi hingga 98,8% dalam deteksi dini kegagalan mesin, menjadikannya ideal untuk *fault detection* dan *condition monitoring* pada mesin guna meningkatkan keberlanjutan dan mengurangi *downtime*. Wu et al., (2017) juga membuktikan bahwa *random forest* unggul dibandingkan model klasik seperti *feed-forward backpropagation artificial neural networks* (FFBP-ANNs) dan *support vector regression* (SVR), khususnya dalam memprediksi kondisi proses mesin. Dengan berbagai keunggulan ini, *random forest* menjadi solusi andal untuk strategi perawatan sistem yang lebih proaktif dan efisien.

Sebelumnya, telah dilakukan penelitian mengenai sistem *predictive maintenance* untuk mendeteksi kegagalan mesin akibat *overstrain*. Sistem yang dirancang Putrada et al., (2023) menggunakan *opensource* Node-Red untuk mengembangkan dashboard yang menampilkan data deteksi anomali. Dalam penelitian ini, hanya digunakan satu model deteksi anomali, yaitu *isolation forest*,

untuk memonitor kondisi mesin berdasarkan dua fitur utama, yaitu *torque* dan *tool wear*.

Dalam penelitian yang dilakukan oleh Moyne et al., (2013), dibahas mengenai pengembangan dan penerapan *equipment health monitoring* (EHM) dan strategi *predictive maintenance* (PdM) dalam industri nano-manufaktur. EHM berfungsi sebagai indikator kesehatan peralatan yang menyediakan data mengenai kondisi alat melalui output deteksi kesalahan, memungkinkan deteksi awal terhadap kondisi tidak normal yang dapat menunjukkan masalah kesehatan alat. Penerapan *predictive maintenance* bertujuan untuk memprediksi kebutuhan pemeliharaan berdasarkan data keadaan proses dan peralatan, sehingga dapat mengurangi *downtime* tak terjadwal, biaya, dan meningkatkan kualitas produk. Fitur dari dashboard EHM mencakup analisis multivariat menggunakan teknik seperti *principle components analysis* (PCA).

Penelitian dari Moens et al., (2021), dikemukakan pendekatan yang menggabungkan teknik deteksi anomali, deteksi kegagalan, dan deteksi peristiwa dalam konteks pemeliharaan prediktif. Penelitian ini menunjukkan pentingnya analisis data sensor dengan memanfaatkan baik pendekatan berbasis pengetahuan maupun berbasis data untuk meningkatkan akurasi deteksi. Pada penelitian tersebut juga menyoroti tantangan yang dihadapi dalam mengintegrasikan informasi dari pengguna ke dalam sistem deteksi, yang pada gilirannya dapat mengurangi upaya pelabelan manual dan menghasilkan label yang lebih bermakna. Hasil dari penelitian ini menegaskan bahwa sinergi antara teknik ini dapat menciptakan dashboard dinamis yang efektif dalam pengawasan dan pemeliharaan aset industri.

Penelitian-penelitian tersebut memiliki spesifikasi beragam dalam pendekatan dan teknologi yang digunakan. Namun, terdapat beberapa *gap* yang masih belum terjawab dalam literatur dan implementasi sistem pemeliharaan prediktif saat ini. Sebagian besar studi sebelumnya hanya berfokus pada satu pendekatan model pembelajaran mesin, seperti hanya deteksi anomali atau deteksi kegagalan, tanpa adanya integrasi menyeluruh antar berbagai metode analitik dalam satu kerangka sistem terpadu. Selain itu, keterbatasan pada visualisasi data dalam satu platform yang intuitif.

Berdasarkan permasalahan tersebut, peneliti mengembangkan sebuah sistem yang mampu mengintegrasikan model *forecasting*, deteksi anomali, dan prediksi kegagalan dalam satu dashboard pemeliharaan prediktif. Sistem ini dirancang untuk memberikan informasi secara *real-time* dan prediktif mengenai kondisi mesin, sehingga dapat meningkatkan efektivitas pemeliharaan serta meminimalkan *downtime*. Pengembangan ini diharapkan menjadi solusi atas keterbatasan penelitian terdahulu yang belum menggabungkan ketiga komponen penting tersebut secara terpadu dalam satu dashboard.

Pengoptimalan kinerja sistem dilakukan melalui proses *hyperparameter tuning* serta evaluasi menyeluruh terhadap tiga pendekatan, yaitu evaluasi model peramalan, evaluasi model deteksi anomali, dan evaluasi model klasifikasi. Evaluasi model peramalan dilakukan untuk mengukur akurasi prediksi terhadap nilai parameter kondisi mesin di masa mendatang. Evaluasi model deteksi anomali digunakan untuk menilai kemampuan model deteksi anomali dalam membedakan antara data normal dan anomali. Sementara itu, evaluasi model klasifikasi dilakukan untuk menilai performa sistem dalam memprediksi potensi kegagalan. Dengan pendekatan ini, sistem yang dikembangkan diharapkan tidak hanya mampu memberikan informasi prediktif, tetapi juga memiliki tingkat akurasi yang tinggi dan dapat diandalkan dalam mendukung pengambilan keputusan pemeliharaan.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana merancang sistem pemeliharaan prediktif dengan mengintegrasikan berbagai model *machine learning* sesuai dengan fungsinya masing-masing?
2. Bagaimana hasil evaluasi model *machine learning* dalam fitur *predictive analytics* dapat mendukung terciptanya sistem pemeliharaan prediktif yang efektif?
3. Bagaimana alur kerja sistem dan visualisasi antarmuka dari hasil model *machine learning* berbasis *website* untuk mendukung sistem *predictive maintenance*?

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Pembelajaran mesin digunakan untuk menciptakan peramalan, deteksi anomali, dan prediksi kegagalan untuk sistem *predictive maintenance*.
2. Perancangan *interface dashboard* berbasis *website*.

1.4 Tujuan Penelitian

Tujuan penelitian ini adalah sebagai berikut:

1. Mengembangkan sistem *predictive maintenance* berbasis pembelajaran mesin yang mampu melakukan peramalan, deteksi anomali, dan prediksi kegagalan pada peralatan industri, serta merancang antarmuka dashboard berbasis *website*.

1.5 Manfaat Penelitian

Manfaat penelitian ini adalah sebagai berikut:

1. Mengembangkan sistem pemeliharaan prediktif dengan kerangka kerja multi model pembelajaran mesin dengan penggunaannya yang berbeda-beda.
2. Menyempurnakan sistem pemeliharaan.
3. Berkontribusi pada literatur ilmiah di bidang teknologi informasi, serta menjadi referensi bagi penelitian di masa mendatang.

1.6 Organisasi Penulisan

Agar pembaca dapat memahami alur penelitian yang dilakukan, struktur organisasi skripsi ini disusun secara sistematis sebagai berikut:

BAB I PENDAHULUAN

Bab ini menyajikan latar belakang penelitian, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan sistematika penulisan.

BAB II KAJIAN PUSTAKA

Bab ini membahas teori-teori dan konsep-konsep yang relevan dengan penelitian.

BAB III METODE PENELITIAN

Bab ini menjelaskan metode dan alur penelitian yang digunakan. Bab ini juga menjelaskan perangkat yang digunakan, prinsip kerja sistem, serta algoritma untuk pengambilan dan penampilan data.

BAB IV HASIL PENELITIAN DAN PEMBAHASAN

Bab ini memaparkan hasil penelitian dan analisis yang telah dilakukan. Proses perancangan sistem, pembuatan purwarupa, serta hasil uji coba sistem dijelaskan secara rinci.

BAB V PENUTUP

Bab ini berisi simpulan dari penelitian yang telah dilakukan dan saran-saran untuk pengembangan lebih lanjut.