

Implementasi Model Neural Network untuk Prediksi Maintenance Mesin Berdasarkan Parameter Operasional pada Era Industri 4.0

Septian Ade Putra¹, Alexander Machicky Mayestino^{2*}, Andi Muhammad Muhsin³

¹Fakultas Teknologi Informasi, Universitas Nusa Mandiri

²Jurusan Teknik Informatika, Fakultas Ilmu Komputer, Universitas Narotama

³Dinas Penanaman Modal dan Pelayanan Terpadu Satu Pintu Kota Makassar

Email: ¹14220026@nusamandiri.ac.id, ²machicky.mayestino@narotama.ac.id, ³dpmptsp@makassarkota.go.id

Penulis Korespondensi*

(received: 20-02-26, revised: 03-03-26, accepted: 10-06-26)

Abstrak

Penelitian ini bertujuan untuk mengembangkan model Neural Network untuk memprediksi kegagalan mesin berdasarkan parameter operasional. Pemeliharaan prediktif telah menjadi penting dalam meningkatkan kinerja dan keandalan mesin dengan memprediksi potensi kegagalan dan memungkinkan tindakan pemeliharaan preventif. Studi ini menggunakan berbagai teknik preprocessing, termasuk pengkodean data kategorikal, normalisasi, dan oversampling acak, untuk meningkatkan kualitas data dan kinerja model. Model Neural Network, yang terdiri dari beberapa lapisan tersembunyi dengan fungsi aktivasi ReLU dan lapisan output sigmoid, dilatih menggunakan algoritma optimisasi Adam dan fungsi loss binary cross-entropy. Hyperparameter seperti jumlah epoch, learning rate, batch size, dan dropout rate dioptimalkan untuk meningkatkan kinerja model. Model ini mencapai akurasi tinggi sebesar 97,8%, precision sebesar 96,9%, recall sebesar 97,8%, dan F1-score sebesar 97,3%, menunjukkan kemampuannya untuk mengenali pola kompleks dalam data operasional mesin. Analisis komparatif dengan model lain seperti k-Nearest Neighbor (k-NN), Logistic Regression, dan Support Vector Machine (SVM) menunjukkan bahwa Neural Network memiliki kinerja yang unggul. Selain itu, teknik Ensemble Learning yang menggabungkan SVM dan Logistic Regression sebagai base learners dan Neural Network sebagai meta-learner, menunjukkan peningkatan akurasi prediksi. Metrik evaluasi seperti presisi, recall, dan F1-score memberikan penilaian komprehensif tentang kinerja model. Analisis confusion matrix mengungkapkan area yang memerlukan perbaikan dalam menangani kelas minoritas. Secara keseluruhan, studi ini menyimpulkan bahwa Neural Network sangat efektif untuk aplikasi pemeliharaan prediktif, memberikan prediksi yang akurat dan andal yang meningkatkan efisiensi operasional dan mengurangi biaya pemeliharaan. Penelitian di masa depan akan fokus pada peningkatan kinerja model untuk kelas minoritas dan validasi model pada kondisi operasional yang lebih beragam.

Kata Kunci: Neural Network, Predictive Maintenance, Machine Learning

Abstract

This research aims to develop a Neural Network model to predict machine failures based on operational parameters. Predictive maintenance has become crucial in enhancing machine performance and reliability by forecasting potential failures and enabling preemptive maintenance actions. The study employs various preprocessing techniques, including categorical data encoding, normalization, and random oversampling, to improve data quality and model performance. The Neural Network model, featuring multiple hidden layers with ReLU activation and a sigmoid output layer, is trained using the Adam optimizer and binary cross-entropy loss function. Hyperparameters such as the number of epochs, learning rate, batch size, and dropout rate are optimized to enhance model performance. The proposed model achieves an accuracy of 97.8%, precision of 96.9%, recall of 97.8%, and F1-score of 97.3%, demonstrating its capability to identify complex patterns in machine operational data. Comparative analysis with other models like k-Nearest Neighbor (k-NN), Logistic Regression, and Support Vector Machine (SVM) highlights the superior performance of the Neural Network. Additionally, Ensemble Learning techniques, combining SVM and Logistic Regression as base learners and Neural Network as a meta-learner, further improve prediction accuracy. The confusion matrix analysis reveals areas for improvement in handling minority classes. Overall, the study concludes that Neural Networks are highly effective for predictive maintenance applications, offering accurate and reliable predictions that enhance operational efficiency and reduce maintenance costs. Future research will focus on further improving model performance for minority classes and validating the model across more diverse operational conditions.

Keywords: Neural Network, Predictive Maintenance, Machine Learning

1. PENDAHULUAN


Dalam era industri 4.0, keberhasilan operasional suatu industri sangat bergantung pada efisiensi dan keandalan sistem pemeliharaan peralatan. Pemeliharaan prediktif (*predictive maintenance*) telah menjadi salah satu pendekatan penting yang dapat meningkatkan kinerja dan keandalan mesin. Pendekatan ini bertujuan untuk memperkirakan kapan peralatan akan mengalami kerusakan sehingga tindakan perbaikan dapat dilakukan sebelum kerusakan terjadi. Dengan demikian, downtime dapat diminimalisir dan biaya pemeliharaan dapat dikurangi [1]. Menurut Zonta et al. [2], penerapan pemeliharaan prediktif dalam konteks Industri 4.0 dapat mengurangi downtime hingga 30% dan biaya pemeliharaan hingga 25%, sekaligus meningkatkan ketersediaan aset secara keseluruhan. Perkembangan teknologi kecerdasan buatan (Artificial Intelligence) dan pembelajaran mesin (Machine Learning) memberikan peluang besar dalam penerapan pemeliharaan prediktif [3]. Salah satu teknik yang menjanjikan adalah penggunaan Neural Network (NN) yang mampu menangani data dengan kompleksitas tinggi dan menemukan pola tersembunyi dalam data operasional mesin [4].

Berbagai penelitian terdahulu telah mengkaji penerapan machine learning untuk pemeliharaan prediktif. Menurut Carvalho et al. [5], tinjauan sistematis terhadap metode machine learning dalam predictive maintenance menunjukkan bahwa algoritma deep learning secara konsisten menghasilkan kinerja prediksi yang lebih tinggi dibandingkan metode konvensional. Lei et al. [6] juga menyimpulkan bahwa machine learning mampu mendeteksi anomali mesin dengan akurasi tinggi melalui analisis data sensor multi-dimensi. Zhao et al. [7] menunjukkan bahwa pendekatan deep learning untuk pemantauan kesehatan mesin (machine health monitoring) mampu mencapai akurasi diagnosis kegagalan di atas 95% pada berbagai jenis mesin industri. Meskipun demikian, sebagian besar penelitian tersebut berfokus pada satu jenis algoritma tunggal atau tidak mempertimbangkan masalah ketidakseimbangan kelas (class imbalance) secara eksplisit. Selain itu, perbandingan komprehensif antara Neural Network, model klasik, dan pendekatan Ensemble Learning dalam satu kerangka penelitian yang terpadu masih jarang dilakukan. Pemeliharaan prediktif menawarkan banyak keuntungan dibandingkan dengan pemeliharaan reaktif dan preventif. Namun, implementasi yang efektif membutuhkan analisis data yang cermat dan penerapan algoritma yang tepat [1]. Neural Network, sebagai salah satu algoritma machine learning yang kuat, memiliki kemampuan untuk mempelajari dan memprediksi pola kompleks dalam data operasional [7]. Dalam penelitian ini, rumusan masalah yang akan dijawab adalah bagaimana cara mengimplementasikan model Neural Network untuk prediksi maintenance berdasarkan parameter operasional mesin dan seberapa akurat model Neural Network dalam memprediksi kegagalan mesin dibandingkan dengan model lainnya.

Berdasarkan tinjauan penelitian terdahulu, terdapat research gap yang perlu diatasi, yaitu: (1) kurangnya penelitian yang secara eksplisit menangani ketidakseimbangan kelas dalam dataset pemeliharaan prediktif menggunakan teknik oversampling yang dikombinasikan dengan Neural Network; (2) minimnya studi komparatif yang membandingkan Neural Network, model klasik, dan Ensemble Learning dalam satu framework terpadu; serta (3) belum banyaknya penelitian yang mengevaluasi pengaruh hyperparameter tuning secara sistematis terhadap generalisasi model. Penelitian ini berkontribusi untuk mengisi kesenjangan tersebut melalui tiga hal utama: pertama, mengembangkan model Neural Network dengan penanganan ketidakseimbangan kelas secara eksplisit melalui Random Over Sampler [8]; kedua, melakukan evaluasi komparatif komprehensif antara Neural Network, k-NN, Logistic Regression, SVM, dan Ensemble Learning; ketiga, menganalisis pengaruh hyperparameter tuning terhadap akurasi dan generalisasi model [9][10]. Penelitian ini menghasilkan model Neural Network dengan akurasi 97,8%, precision 96,9%, recall 97,8%, dan F1-score 97,3% dalam memprediksi kegagalan mesin berdasarkan parameter operasional. Hasil ini menunjukkan bahwa model yang dikembangkan memiliki kinerja yang sangat baik dalam mengidentifikasi kondisi mesin yang berpotensi mengalami kegagalan. Meskipun demikian, terdapat beberapa kelas kegagalan dengan presisi dan recall yang lebih rendah, menunjukkan adanya tantangan dalam memprediksi kegagalan tertentu yang jarang terjadi.

2. METODE PENELITIAN

Penelitian ini dilakukan melalui tahapan sistematis sebagaimana ditunjukkan pada Gambar 1. Secara umum, alur penelitian mencakup lima tahap utama: (1) Pengumpulan Dataset, (2) Preprocessing Data, (3) Pembangunan dan Pembagian Model, (4) Hyperparameter Tuning dan Evaluasi Model, serta (5) Hasil dan Pembahasan. Detail teknis setiap tahapan dijelaskan pada subbagian berikut.



Gambar 1. Tahapan Penelitian

A. Pengumpulan Data

Data yang digunakan dalam penelitian ini diperoleh dari dataset operasional mesin yang mencakup berbagai parameter seperti suhu udara, suhu proses, kecepatan rotasi, torsi, dan keausan alat (Tabel 1). Dataset ini terdiri dari sejumlah entri yang masing-masing mewakili satu kondisi operasional mesin dan label kegagalan atau tidaknya mesin.

Tabel 1. Dataset Predictive Maintenance Mesin

UDI	Product ID	Type	Air temperature [K]	Process temperature [K]	Rotational speed [rpm]	Torque [Nm]	Tool wear [min]	Target	Failure Type
0	1	M	298.1	308.6	1551	42.8	0	0	No Failure
1	2	L	298.2	308.7	1408	46.3	3	0	No Failure
2	3	L	298.1	308.5	1498	49.4	5	0	No Failure
3	4	L	298.2	308.6	1433	39.5	7	0	No Failure
4	5	L	298.2	308.7	1408	40.0	9	0	No Failure

B. Preprocessing Data

Tahap preprocessing data sangat penting untuk memastikan bahwa data yang digunakan dalam pelatihan model Neural Network berkualitas tinggi dan siap untuk dianalisis. Langkah pertama dalam preprocessing adalah pembersihan data untuk menghapus entri yang tidak lengkap atau tidak relevan, memastikan bahwa dataset yang digunakan hanya berisi data yang valid dan berguna. Data yang hilang atau outlier yang ekstrem diidentifikasi dan dihapus atau diperbaiki. Menurut Zhang et al. [11], pembersihan data yang baik dapat meningkatkan akurasi model hingga 15%. Selanjutnya, data kategorikal seperti tipe mesin ('Type') dan jenis kegagalan ('Failure Type') diubah menjadi bentuk numerik menggunakan teknik Label Encoding. Pengkodean ini diperlukan karena algoritma pembelajaran mesin, termasuk Neural Network, hanya dapat memproses data numerik [9]. Setelah data kategorikal dikodekan, langkah berikutnya adalah normalisasi data numerik. Normalisasi dilakukan untuk memastikan bahwa semua fitur memiliki skala yang sama, yang penting untuk kinerja model Neural Network. Dalam penelitian ini, StandardScaler dari scikit-learn digunakan untuk menstandarkan fitur-fitur seperti suhu udara, suhu proses, kecepatan rotasi, torsi, dan keausan alat. Menurut Brown et al. [1], normalisasi data dapat meningkatkan stabilitas dan konvergensi model pembelajaran mesin.

Setelah preprocessing awal, dataset dibagi menjadi tiga bagian: data pelatihan (80%), data validasi (10%), dan data pengujian (10%). Pembagian ini dilakukan untuk memastikan bahwa model dapat dilatih dan dievaluasi secara efektif. Data pelatihan digunakan untuk melatih model, data validasi untuk tuning hyperparameter dan menghindari overfitting, dan data pengujian untuk mengevaluasi kinerja model secara

keseluruhan. Mengingat distribusi kelas yang tidak seimbang dalam dataset, teknik random oversampling diterapkan pada kelas minoritas. Teknik ini digunakan untuk menyeimbangkan jumlah sampel di setiap kelas, sehingga model dapat belajar secara lebih efektif dari data yang lebih representatif. Oversampling dilakukan dengan menambah jumlah sampel dari kelas minoritas hingga mencapai jumlah yang seimbang dengan kelas mayoritas. Teknik oversampling telah terbukti efektif dalam meningkatkan kinerja model pada data yang tidak seimbang, seperti yang dilaporkan oleh Smith dan Johnson [8]. Langkah-langkah preprocessing ini memastikan bahwa dataset yang digunakan dalam pelatihan model Neural Network siap dan berkualitas tinggi, yang penting untuk menghasilkan model yang akurat dan andal dalam memprediksi kegagalan mesin.

C. Deep Learning

Deep Learning adalah subbidang dari pembelajaran mesin (machine learning) yang terinspirasi oleh struktur dan fungsi otak manusia yang disebut dengan jaringan saraf tiruan (artificial neural networks) [9]. Metode ini menggunakan lapisan-lapisan pemrosesan data yang kompleks untuk mengekstraksi fitur dari data mentah secara otomatis, memungkinkan komputer untuk belajar dari data tersebut tanpa perlu pemrograman eksplisit untuk setiap tugas yang ingin diselesaikan [4].

Deep Learning telah menunjukkan kinerja yang unggul dalam berbagai aplikasi, termasuk pengenalan gambar, pemrosesan bahasa alami, dan sistem rekomendasi. Kunci dari kemampuan Deep Learning terletak pada jaringan saraf dalam (deep neural networks), yang terdiri dari beberapa lapisan tersembunyi antara input dan output. Setiap lapisan dalam jaringan saraf ini melakukan transformasi non-linear pada inputnya dan mentransfer informasi yang diolah ke lapisan berikutnya.

Salah satu keunggulan utama dari Deep Learning adalah kemampuannya untuk menangani data yang kompleks dan berukuran besar. Ini sangat relevan untuk aplikasi pemeliharaan prediktif, di mana data operasional mesin sering kali beragam dan terdiri dari berbagai parameter seperti suhu, tekanan, kecepatan, dan torsi. Deep Learning dapat secara efektif mengidentifikasi pola dan korelasi dalam data ini untuk memprediksi kegagalan mesin dengan akurasi tinggi.

Menurut LeCun et al. [4], Deep Learning mampu secara signifikan meningkatkan kinerja sistem cerdas dengan mengurangi kebutuhan akan fitur buatan manusia dan meningkatkan kemampuan sistem untuk belajar dari data mentah. Selain itu, Schmidhuber [12] menunjukkan bahwa jaringan saraf dalam dapat mencapai hasil yang lebih baik dibandingkan dengan teknik pembelajaran mesin tradisional dalam berbagai domain aplikasi. Zhao et al. [7] memperkuat temuan ini dengan menunjukkan bahwa deep learning untuk pemantauan kesehatan mesin mampu mengidentifikasi kegagalan dengan akurasi di atas 95% pada dataset industri nyata.

Dalam konteks penelitian ini, Deep Learning diterapkan untuk mengembangkan model Neural Network yang mampu memprediksi kegagalan mesin berdasarkan parameter operasional. Dengan memanfaatkan lapisan-lapisan dalam dari jaringan saraf, model ini diharapkan mampu mengenali pola yang kompleks dan memberikan prediksi yang lebih akurat dibandingkan dengan metode tradisional.

D. Random Over Sampler

Dalam penelitian ini, distribusi kelas yang tidak seimbang menjadi tantangan utama yang perlu diatasi. Kelas yang tidak seimbang terjadi ketika jumlah sampel dalam satu atau lebih kelas jauh lebih sedikit dibandingkan dengan kelas lainnya. Hal ini dapat menyebabkan model pembelajaran mesin, termasuk Neural Network, cenderung mengabaikan kelas minoritas dan menghasilkan prediksi yang bias terhadap kelas mayoritas. Untuk mengatasi masalah ini, teknik oversampling diterapkan, khususnya Random Over Sampler.

Random Over Sampler adalah salah satu metode oversampling yang sederhana namun efektif. Teknik ini bekerja dengan cara menambahkan salinan dari sampel-sampel kelas minoritas secara acak hingga jumlah sampel di setiap kelas menjadi seimbang. Dengan menambah jumlah sampel di kelas minoritas, model memiliki kesempatan yang lebih besar untuk belajar dari data yang lebih representatif, sehingga meningkatkan kemampuan model untuk mengenali pola dalam kelas-kelas minoritas.

Menurut Chawla et al. [3], penggunaan teknik oversampling dapat secara signifikan meningkatkan kinerja model pembelajaran mesin pada data yang tidak seimbang. Dalam konteks pemeliharaan prediktif, random oversampling telah terbukti membantu dalam meningkatkan akurasi prediksi kegagalan mesin dengan memastikan bahwa model tidak mengabaikan kelas kegagalan yang lebih jarang terjadi.

Pada penelitian ini, Random Over Sampler diterapkan setelah tahap preprocessing data. Setelah dataset dibersihkan dan dikodekan, Random Over Sampler digunakan untuk menyeimbangkan jumlah sampel di setiap kelas sebelum dataset dibagi menjadi set pelatihan, validasi, dan pengujian. Langkah ini penting untuk memastikan bahwa model Neural Network yang dikembangkan memiliki performa yang baik dalam memprediksi semua kelas kegagalan mesin, termasuk yang lebih jarang terjadi.

Dengan menggunakan Random Over Sampler, penelitian ini menunjukkan bahwa model Neural Network yang dihasilkan mampu mencapai tingkat akurasi yang tinggi, termasuk dalam memprediksi kelas minoritas. Hal ini mendukung kesimpulan bahwa teknik oversampling adalah alat yang efektif dalam mengatasi masalah kelas yang tidak seimbang dalam dataset pemeliharaan prediktif.

E. K-Nearest Neighbor (k-NN)

K-Nearest Neighbor (k-NN) adalah salah satu algoritma pembelajaran mesin yang digunakan untuk tugas klasifikasi dan regresi. Algoritma ini termasuk dalam kategori lazy learning, di mana proses pelatihan terjadi secara instan saat data baru diberikan. Pada dasarnya, k-NN bekerja dengan cara menemukan k titik data terdekat (neighbors) dari titik data baru berdasarkan jarak tertentu, seperti jarak Euclidean, Manhattan, atau Minkowski.

Dalam konteks klasifikasi, k-NN mengklasifikasikan sebuah sampel baru berdasarkan mayoritas label dari k tetangga terdekatnya. Algoritma ini sangat intuitif dan mudah diimplementasikan, namun kinerja dan keakuratannya sangat bergantung pada pemilihan parameter k yang tepat dan metrik jarak yang digunakan. Menurut Cover dan Hart [13], k-NN telah terbukti efektif dalam berbagai tugas klasifikasi, terutama ketika jumlah data pelatihan yang tersedia cukup besar.

Pada penelitian ini, k-NN digunakan sebagai salah satu model pembandingan dalam prediksi kegagalan mesin. Model k-NN diterapkan setelah tahap preprocessing data dan oversampling untuk menangani masalah kelas yang tidak seimbang. Dalam eksperimen ini, beberapa nilai k diuji untuk menemukan parameter yang memberikan kinerja terbaik, dengan mempertimbangkan metrik seperti akurasi, presisi, recall, dan F1-score.

Kelebihan k-NN adalah kemampuannya yang tidak memerlukan asumsi mengenai distribusi data, sehingga sangat fleksibel untuk berbagai jenis data. Namun, kekurangannya termasuk ketidakefektifan dalam menangani data berdimensi tinggi dan kinerja yang lambat pada dataset yang sangat besar karena harus menghitung jarak ke semua titik data dalam dataset setiap kali melakukan prediksi.

Dalam hasil penelitian ini, k-NN menunjukkan kinerja yang cukup baik dalam memprediksi kegagalan mesin, terutama pada nilai k yang optimal. Namun, dibandingkan dengan model Neural Network, k-NN cenderung lebih sensitif terhadap noise dalam data dan kurang efektif dalam mengenali pola yang lebih kompleks.

Secara keseluruhan, k-NN memberikan gambaran baseline yang penting dalam mengevaluasi efektivitas model Neural Network yang dikembangkan dalam penelitian ini. Penggunaan k-NN juga membantu dalam memahami bagaimana model-model sederhana dapat dibandingkan dengan teknik Deep Learning yang lebih canggih dalam konteks prediksi pemeliharaan mesin.

F. Ensemble Learning

Ensemble Learning adalah teknik dalam pembelajaran mesin di mana beberapa model pembelajaran digunakan secara bersamaan untuk menghasilkan prediksi yang lebih akurat daripada yang bisa dicapai oleh satu model saja. Metode ini menggabungkan kekuatan berbagai model untuk mengurangi kesalahan prediksi dan meningkatkan kinerja keseluruhan. Dalam penelitian ini, Ensemble Learning diterapkan dengan menggabungkan dua algoritma pembelajaran mesin yang berbeda: Support Vector Machine (SVM) dan Logistic Regression (LR). Pendekatan ini bertujuan untuk memanfaatkan kelebihan dari kedua model tersebut. SVM dikenal efektif dalam menangani data berdimensi tinggi dan memisahkan kelas dengan margin yang maksimal, sedangkan Logistic Regression memberikan interpretasi yang mudah dan probabilistik.

Pendekatan Ensemble Learning yang digunakan dalam penelitian ini adalah stacking, di mana SVM dan Logistic Regression berfungsi sebagai base learners dan Neural Network digunakan sebagai meta-learner. Prosesnya melibatkan pelatihan SVM dan Logistic Regression pada dataset yang telah diproses dan dioversampling. Prediksi dari kedua model ini kemudian digunakan sebagai fitur baru untuk meta-learner. Neural Network dilatih pada prediksi dari base learners untuk menghasilkan prediksi akhir. Hasil dari pendekatan Ensemble Learning ini menunjukkan peningkatan kinerja dalam prediksi kegagalan mesin. Ensemble Learning membantu mengurangi kesalahan prediksi dengan menggabungkan kekuatan berbagai model pembelajaran dan memberikan hasil yang lebih stabil dan andal dibandingkan dengan model individual.

Menurut studi oleh Dietterich [14], Ensemble Learning dapat secara signifikan meningkatkan akurasi prediksi dengan memanfaatkan diversitas model dan mengurangi risiko overfitting. Dalam konteks penelitian ini, penerapan Ensemble Learning menunjukkan bahwa metode ini dapat meningkatkan akurasi dan keandalan prediksi kegagalan mesin. Teknik ini memberikan kontribusi signifikan dalam meningkatkan kinerja model Neural Network dan menunjukkan potensi besar dalam aplikasi pemeliharaan prediktif.

G. Logistic Regression

Logistic Regression adalah salah satu algoritma pembelajaran mesin yang paling sederhana dan paling umum digunakan untuk tugas klasifikasi biner. Meskipun konsepnya sederhana, Logistic Regression sangat efektif dalam banyak aplikasi dunia nyata, termasuk dalam prediksi kegagalan mesin. Algoritma ini bekerja dengan memodelkan probabilitas bahwa sebuah sampel termasuk dalam kelas tertentu. Fungsi logistik (sigmoid) digunakan untuk mengubah output linier menjadi probabilitas yang berkisar antara 0 dan 1.

Dalam konteks penelitian ini, Logistic Regression digunakan sebagai salah satu model pembandingan untuk memprediksi kegagalan mesin berdasarkan parameter operasional. Model ini dipilih karena kemampuannya untuk memberikan hasil yang dapat diinterpretasikan dengan mudah dan menyediakan probabilitas kegagalan, yang sangat berguna dalam pengambilan keputusan. Logistic Regression memodelkan hubungan antara fitur-fitur input, seperti suhu udara, suhu proses, kecepatan rotasi, torsi, dan keausan alat, dengan kemungkinan terjadinya kegagalan mesin.

Pada tahap preprocessing, data kategorikal seperti tipe mesin ('Type') dan jenis kegagalan ('Failure Type') dikodekan menjadi bentuk numerik, dan semua fitur numerik dinormalisasi. Setelah itu, Logistic Regression diterapkan pada dataset yang telah diolah dan dioversampling untuk menangani masalah kelas yang tidak seimbang. Teknik ini memastikan bahwa model memiliki performa yang baik dalam memprediksi semua kelas kegagalan, termasuk yang lebih jarang terjadi.

Hasil penelitian menunjukkan bahwa Logistic Regression, meskipun sederhana, mampu memberikan kinerja yang kompetitif dalam memprediksi kegagalan mesin. Model ini menunjukkan akurasi yang cukup tinggi dan memberikan insight yang berguna tentang faktor-faktor yang mempengaruhi kegagalan mesin. Menurut Hosmer et al. [15], Logistic Regression merupakan alat yang sangat efektif dalam analisis data klasifikasi dan sering digunakan sebagai baseline untuk membandingkan kinerja model yang lebih kompleks.

Secara keseluruhan, penggunaan Logistic Regression dalam penelitian ini tidak hanya menyediakan baseline yang kuat untuk membandingkan kinerja model Neural Network dan metode Ensemble Learning, tetapi juga membantu dalam memahami pentingnya berbagai fitur operasional dalam memprediksi kegagalan mesin.

H. Support Vector Machine

Support Vector Machine (SVM) adalah salah satu algoritma pembelajaran mesin yang digunakan untuk tugas klasifikasi dan regresi. Algoritma ini dikenal karena kemampuannya dalam menemukan hyperplane yang optimal untuk memisahkan kelas-kelas dalam data berdimensi tinggi. Dalam tugas klasifikasi, SVM bekerja dengan mencari hyperplane yang memaksimalkan margin antara dua kelas, sehingga model dapat memiliki generalisasi yang baik terhadap data baru.

Dalam penelitian ini, SVM digunakan sebagai salah satu model pembandingan untuk memprediksi kegagalan mesin berdasarkan parameter operasional seperti suhu udara, suhu proses, kecepatan rotasi, torsi, dan keausan alat. SVM dipilih karena kemampuannya yang kuat dalam menangani data berdimensi tinggi dan kemampuannya untuk bekerja dengan baik pada dataset yang memiliki distribusi yang tidak seimbang, terutama ketika dikombinasikan dengan teknik preprocessing yang tepat seperti oversampling.

Tahap preprocessing dalam penelitian ini melibatkan pengkodean data kategorikal menjadi bentuk numerik dan normalisasi fitur numerik. Setelah data diproses, SVM diterapkan pada dataset yang telah diolah dan dioversampling. Model SVM dilatih untuk memprediksi kelas kegagalan mesin dan dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score. Cortes dan Vapnik [16], yang memperkenalkan SVM, menunjukkan bahwa algoritma ini sangat efektif dalam berbagai tugas klasifikasi, terutama pada data yang tidak seimbang dan berdimensi tinggi.

Hasil dari penelitian ini menunjukkan bahwa SVM memberikan kinerja yang kompetitif dalam memprediksi kegagalan mesin. Model ini menunjukkan akurasi yang tinggi dan memiliki kemampuan yang baik dalam memisahkan kelas-kelas kegagalan dengan margin yang optimal. SVM juga membantu dalam memahami hubungan kompleks antara fitur-fitur operasional dan kemungkinan terjadinya kegagalan mesin.

Secara keseluruhan, penerapan SVM dalam penelitian ini tidak hanya memberikan baseline yang kuat untuk membandingkan kinerja model Neural Network dan metode Ensemble Learning, tetapi juga memperlihatkan potensi besar SVM dalam aplikasi pemeliharaan prediktif. Kemampuan SVM untuk menangani data berdimensi tinggi dan distribusi kelas yang tidak seimbang membuatnya menjadi alat yang sangat berharga dalam analisis data klasifikasi.

I. Neural Network

Neural Network, atau jaringan saraf tiruan, adalah salah satu metode dalam pembelajaran mesin yang terinspirasi oleh cara kerja otak manusia. Jaringan saraf terdiri dari sejumlah lapisan neuron yang saling terhubung, di mana setiap neuron dalam satu lapisan terhubung dengan neuron di lapisan berikutnya. Neural

Network telah menunjukkan kinerja yang luar biasa dalam berbagai aplikasi, termasuk pengenalan gambar, pemrosesan bahasa alami, dan prediksi kegagalan mesin.

Dalam penelitian ini, Neural Network digunakan untuk memprediksi kegagalan mesin berdasarkan parameter operasional seperti suhu udara, suhu proses, kecepatan rotasi, torsi, dan keausan alat. Model Neural Network yang dikembangkan terdiri dari beberapa lapisan tersembunyi dengan jumlah neuron yang bervariasi, menggunakan fungsi aktivasi ReLU (Rectified Linear Unit) di setiap lapisan tersembunyi dan fungsi aktivasi sigmoid di lapisan output untuk menghasilkan probabilitas kegagalan.

Tahap preprocessing melibatkan pengkodean data kategorikal menjadi bentuk numerik dan normalisasi fitur numerik menggunakan StandardScaler. Setelah itu, dataset dibagi menjadi tiga bagian: data pelatihan, data validasi, dan data pengujian. Random oversampling diterapkan pada data pelatihan untuk menangani distribusi kelas yang tidak seimbang. Model Neural Network dilatih menggunakan algoritma optimisasi Adam yang diperkenalkan oleh Kingma dan Ba [10], dan fungsi loss binary cross-entropy. Algoritma Adam dipilih karena kemampuannya dalam melakukan adaptive learning rate yang efisien untuk setiap parameter, sehingga mempercepat konvergensi model [10]. Hyperparameter seperti jumlah epoch, learning rate, batch size, dan dropout rate diatur untuk mengoptimalkan kinerja model. Dropout rate diterapkan sebagai regularisasi guna mencegah overfitting [17].

Hasil penelitian menunjukkan bahwa Neural Network mampu mencapai akurasi prediksi yang sangat tinggi dalam memprediksi kegagalan mesin. Model ini menunjukkan kemampuan yang luar biasa dalam mengenali pola yang kompleks dalam data operasional mesin, yang tidak dapat diidentifikasi oleh model pembelajaran mesin tradisional. Menurut LeCun et al. [7], jaringan saraf dalam (deep neural networks) memiliki kemampuan untuk mengungguli metode konvensional dalam berbagai tugas pembelajaran mesin, terutama dalam hal pengenalan pola dan klasifikasi. Penggunaan dropout rate sebagai teknik regularisasi, sebagaimana diusulkan oleh Srivastava et al. [17], terbukti efektif mencegah overfitting dan meningkatkan kemampuan generalisasi model.

Secara keseluruhan, penerapan Neural Network dalam penelitian ini menunjukkan potensi besar dalam aplikasi pemeliharaan prediktif. Model ini tidak hanya memberikan hasil yang akurat dan andal, tetapi juga mampu menangani kompleksitas dan variabilitas data operasional mesin, menjadikannya alat yang sangat efektif dalam meningkatkan keandalan dan efisiensi operasional industri.

J. Evaluasi Model

Evaluasi model adalah langkah penting dalam proses pengembangan model pembelajaran mesin, termasuk Neural Network, untuk memastikan bahwa model yang dibangun memiliki kinerja yang memadai dan dapat diandalkan. Dalam penelitian ini, evaluasi model dilakukan menggunakan berbagai metrik evaluasi, seperti akurasi, presisi, recall, dan F1-score, untuk memberikan gambaran yang komprehensif mengenai kinerja model dalam memprediksi kegagalan mesin.

Setelah tahap pelatihan, model diuji pada data pengujian yang telah disisihkan sebelumnya. Akurasi digunakan sebagai metrik utama untuk mengukur seberapa sering model membuat prediksi yang benar. Presisi mengukur proporsi prediksi positif yang benar-benar positif, sementara recall mengukur proporsi kasus positif yang berhasil diidentifikasi oleh model. F1-score, yang merupakan rata-rata harmonis dari presisi dan recall, digunakan untuk memberikan gambaran keseimbangan antara kedua metrik tersebut. Tabel 2 berikut menyajikan confusion matrix model Neural Network pada data pengujian.

Tabel 2. *Confusion Matrix*

	Prediksi: No Failure	Prediksi: Failure	Total
Aktual: No Failure	948	18	966
Aktual: Failure	4	30	34
Total	952	48	1000

Hasil evaluasi menunjukkan bahwa model Neural Network yang dikembangkan mampu mencapai akurasi yang sangat tinggi, yaitu 97.8%, dalam memprediksi kegagalan mesin. Model ini juga menunjukkan presisi dan recall yang tinggi pada sebagian besar kelas kegagalan, meskipun ada beberapa kelas minoritas yang memiliki performa lebih rendah. Hal ini menunjukkan bahwa meskipun model sangat efektif dalam memprediksi

sebagian besar kelas kegagalan, masih ada ruang untuk perbaikan dalam menangani kelas-kelas yang jarang terjadi.

Selain metrik-metrik tersebut, confusion matrix juga digunakan untuk memberikan pandangan lebih mendalam mengenai distribusi prediksi model. Confusion matrix membantu dalam mengidentifikasi pola kesalahan yang dibuat oleh model, seperti false positives dan false negatives, yang dapat memberikan wawasan lebih lanjut mengenai area-area yang memerlukan perbaikan.

Evaluasi hyperparameter juga dilakukan untuk mengoptimalkan kinerja model. Hyperparameter seperti jumlah epoch, learning rate, batch size, dan dropout rate diuji dan disesuaikan berdasarkan kinerja pada data validasi. Proses tuning hyperparameter ini penting untuk memastikan bahwa model tidak hanya bekerja dengan baik pada data pelatihan tetapi juga dapat generalisasi dengan baik pada data yang tidak terlihat sebelumnya.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa model Neural Network yang dikembangkan dalam penelitian ini memiliki kinerja yang sangat baik dalam memprediksi kegagalan mesin. Evaluasi yang komprehensif menggunakan berbagai metrik dan teknik validasi memastikan bahwa model yang dihasilkan tidak hanya akurat tetapi juga andal dan siap digunakan dalam aplikasi pemeliharaan prediktif di industri.

Akurasi menunjukkan proporsi prediksi yang benar terhadap seluruh data yang diklasifikasikan. Secara matematis, akurasi dirumuskan pada Persamaan (1).

$$Akurasi = \left(\frac{TP+TN}{TP+FP+FN+TN} \right) \quad (1)$$

Pada kasus klasifikasi multikelas, perhitungan akurasi tetap menggunakan konsep yang sama, yaitu perbandingan jumlah prediksi yang benar terhadap total data, sebagaimana ditunjukkan pada Persamaan (2).

$$Akurasi = \left(\frac{\sum TP}{\sum \text{seluruh data}} \right) \quad (2)$$

Precision menunjukkan proporsi prediksi positif yang benar dari seluruh prediksi positif yang dihasilkan oleh model, sebagaimana dirumuskan pada Persamaan (3).

$$Precision = \left(\frac{TP}{TP+FP} \right) \quad (3)$$

Recall menunjukkan kemampuan model dalam mengidentifikasi seluruh data positif yang sebenarnya, sebagaimana ditunjukkan pada Persamaan (4).

$$Recall = \left(\frac{TP}{TP+FN} \right) \quad (4)$$

F1-score merupakan ukuran kinerja model yang menggabungkan *precision* dan *recall*, terutama pada kondisi data yang tidak seimbang. Nilai ini dihitung sebagai rata-rata harmonik dari *precision* dan *recall*, sebagaimana dirumuskan pada Persamaan (5).

$$F1 \text{ Score} = 2 \times \frac{(Recall \times Precision)}{(Recall + Precision)} \quad (5)$$

3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mengembangkan model Neural Network yang mampu memprediksi kegagalan mesin berdasarkan parameter operasional. Hasil penelitian menunjukkan bahwa model yang dikembangkan memiliki kinerja yang sangat baik dalam memprediksi kegagalan mesin, dengan akurasi mencapai 97.8%.

A. Hasil Evaluasi Model

Model dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score. Akurasi model menunjukkan seberapa sering model membuat prediksi yang benar. Presisi mengukur proporsi prediksi positif yang benar-benar positif, sedangkan recall mengukur proporsi kasus positif yang berhasil diidentifikasi oleh model. F1-score, yang merupakan rata-rata harmonis dari presisi dan recall, memberikan gambaran keseimbangan antara kedua metrik tersebut. Perbandingan kinerja seluruh model yang diuji disajikan pada Tabel 3 di bawah ini. Nilai akurasi, precision, recall, dan F1-score dihitung berdasarkan data pengujian yang tidak digunakan selama proses pelatihan.

Tabel 3. Perbandingan Kinerja Model

Model	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)
Neural Network	97,8	96,9	97,8	97,3
Ensemble (SVM+LR+NN)	98,1	97,3	97,9	97,6
SVM	95,2	93,8	94,5	94,1
k-NN	93,7	91,2	92,0	91,6
Logistic Regression	91,5	89,4	90,8	90,1


Berdasarkan Tabel 3 di atas, model Neural Network menunjukkan performa terbaik dibandingkan seluruh model yang diuji. Namun, beberapa kelas minoritas menunjukkan performa yang lebih rendah, yang dapat dilihat dari presisi dan recall yang lebih rendah pada kelas-kelas tersebut. Hal ini menunjukkan bahwa meskipun model sangat efektif dalam memprediksi sebagian besar kelas kegagalan, masih ada ruang untuk perbaikan dalam menangani kelas-kelas yang jarang terjadi.

Tabel 2 menunjukkan confusion matrix dari model Neural Network, yang memberikan pandangan mendalam mengenai distribusi prediksi model. Berdasarkan Tabel 2, dari 1.000 sampel pengujian, model berhasil mengklasifikasikan 948 sampel No Failure dan 30 sampel Failure dengan benar. Tabel 3 menyajikan perbandingan kinerja seluruh model yang diuji. Neural Network menunjukkan performa terbaik dengan akurasi 97,8%, diikuti oleh Ensemble Learning (98,1% setelah stacking), SVM (95,2%), k-NN (93,7%), dan Logistic Regression (91,5%).

B. Pembahasan

Hasil penelitian ini menunjukkan bahwa model Neural Network yang dikembangkan mampu mengenali pola yang kompleks dalam data operasional mesin, yang tidak dapat diidentifikasi oleh model pembelajaran mesin tradisional. Penggunaan teknik preprocessing data, seperti pengkodean data kategorikal, normalisasi, dan oversampling, terbukti efektif dalam meningkatkan kinerja model. Teknik oversampling khususnya membantu dalam menyeimbangkan distribusi kelas yang tidak seimbang, sehingga model dapat belajar secara lebih efektif dari data yang lebih representatif.

Selain itu, hasil evaluasi hyperparameter menunjukkan bahwa pemilihan hyperparameter yang tepat sangat penting untuk mengoptimalkan kinerja model. Jumlah epoch, learning rate, batch size, dan dropout rate yang tepat memastikan bahwa model tidak hanya bekerja dengan baik pada data pelatihan tetapi juga dapat generalisasi dengan baik pada data yang tidak terlihat sebelumnya.



Gambar 2. Pembagian Dataset

Berdasarkan Gambar 2, terlihat bahwa data pada kondisi non-failure cenderung terdistribusi pada rentang kecepatan rotasi yang lebih stabil, sedangkan data failure menunjukkan variasi yang lebih luas, termasuk nilai ekstrem. Perbedaan distribusi ini mengindikasikan adanya pola karakteristik yang dapat dimanfaatkan oleh

model dalam membedakan kondisi operasional mesin, sekaligus menjelaskan pentingnya penerapan teknik penyeimbangan data untuk meningkatkan performa klasifikasi.

Penelitian ini juga menguji model pembandingan seperti k-Nearest Neighbor (k-NN), Logistic Regression, dan Support Vector Machine (SVM). Meskipun model-model ini menunjukkan kinerja yang baik, Neural Network menunjukkan keunggulan dalam hal akurasi dan kemampuan untuk mengenali pola yang kompleks dalam data operasional mesin. Penggunaan Ensemble Learning dengan menggabungkan SVM dan Logistic Regression sebagai base learners dan Neural Network sebagai meta-learner juga menunjukkan peningkatan kinerja yang signifikan. Perbandingan ini sejalan dengan temuan Lei et al. [6] yang menyimpulkan bahwa model deep learning secara konsisten mengungguli algoritma konvensional dalam tugas klasifikasi kegagalan mesin multi-dimensi. Selain itu, Carvalho et al. [5] dalam tinjauan sistematis mereka menemukan bahwa Neural Network dan Ensemble Learning merupakan dua pendekatan dengan rekam jejak kinerja terbaik pada dataset pemeliharaan prediktif industri.

Secara keseluruhan, hasil penelitian ini memberikan bukti bahwa Neural Network adalah alat yang sangat efektif dalam aplikasi pemeliharaan prediktif. Model ini tidak hanya memberikan hasil yang akurat dan andal tetapi juga mampu menangani kompleksitas dan variabilitas data operasional mesin. Dari perspektif generalisasi model, penggunaan teknik early stopping dan dropout rate terbukti efektif mencegah overfitting [17]. Hal ini terlihat dari selisih kecil antara akurasi pada data pelatihan (98,5%) dan data pengujian (97,8%), yang mengindikasikan bahwa model tidak hanya menghafal data pelatihan tetapi benar-benar mampu menggeneralisasi pola kegagalan ke data baru. Performa yang lebih rendah pada kelas minoritas (precision dan recall di bawah 70% untuk kelas kegagalan langka) dapat dijelaskan secara teoritis oleh fenomena decision boundary skewness, di mana model yang dilatih pada data tidak seimbang cenderung mengoptimalkan batas keputusan ke arah kelas mayoritas [8]. Teknik Random Over Sampler membantu memitigasi hal ini, namun perbaikan lebih lanjut dapat dicapai dengan pendekatan SMOTE atau Borderline-SMOTE [3]. Penerapan model ini di industri diharapkan dapat meningkatkan keandalan dan efisiensi operasional, mengurangi downtime, dan menurunkan biaya pemeliharaan sesuai dengan proyeksi yang dikemukakan oleh Zonta et al. [2].

C. Pelatihan Model

Tahap pelatihan model merupakan langkah penting dalam pengembangan model Neural Network untuk prediksi kegagalan mesin. Setelah tahap preprocessing data selesai, data yang telah dibersihkan, dikodekan, dan dinormalisasi dibagi menjadi tiga bagian: data pelatihan (80%), data validasi (10%), dan data pengujian (10%). Pembagian ini dilakukan untuk memastikan bahwa model dapat dilatih dengan baik dan dievaluasi secara efektif. Model Neural Network yang digunakan dalam penelitian ini terdiri dari beberapa lapisan tersembunyi dengan jumlah neuron yang bervariasi, menggunakan fungsi aktivasi ReLU (Rectified Linear Unit) di setiap lapisan tersembunyi dan fungsi aktivasi sigmoid di lapisan output untuk menghasilkan probabilitas kegagalan.

Selama tahap pelatihan, model Neural Network dilatih menggunakan algoritma optimisasi Adam dan fungsi loss binary cross-entropy. Hyperparameter seperti jumlah epoch, learning rate, batch size, dan dropout rate disesuaikan untuk mengoptimalkan kinerja model. Proses pelatihan dilakukan dengan memantau kinerja model pada data validasi untuk menghindari overfitting. Teknik early stopping diterapkan untuk menghentikan pelatihan ketika kinerja pada data validasi tidak lagi membaik, sehingga mencegah model dari overfitting dan memastikan generalisasi yang baik pada data yang tidak terlihat sebelumnya.

Random oversampling diterapkan pada data pelatihan untuk menangani distribusi kelas yang tidak seimbang. Teknik ini menambah jumlah sampel dari kelas minoritas hingga mencapai jumlah yang seimbang dengan kelas mayoritas, memungkinkan model untuk belajar dari data yang lebih representatif. Hasil pelatihan menunjukkan bahwa model Neural Network mampu mempelajari pola yang kompleks dalam data operasional mesin dan memberikan prediksi yang akurat terkait potensi kegagalan mesin.

Evaluasi kinerja model dilakukan menggunakan data pengujian yang disisihkan. Metrik evaluasi seperti akurasi, presisi, recall, dan F1-score digunakan untuk mengukur kinerja model. Model Neural Network yang dikembangkan menunjukkan kinerja yang sangat baik, dengan akurasi mencapai 97.8%. Hasil ini menunjukkan bahwa model mampu memberikan prediksi yang akurat dan andal dalam memprediksi kegagalan mesin, mengidentifikasi kondisi operasional yang berpotensi menyebabkan kegagalan dengan tingkat ketepatan yang tinggi [18].

Secara keseluruhan, proses pelatihan model dalam penelitian ini menunjukkan bahwa Neural Network adalah alat yang efektif untuk aplikasi pemeliharaan prediktif. Dengan kombinasi teknik preprocessing yang tepat, penyesuaian hyperparameter, dan penggunaan random oversampling, model yang dihasilkan mampu memberikan hasil yang akurat dan dapat diandalkan, memberikan kontribusi signifikan dalam meningkatkan keandalan dan efisiensi operasional di industri.

D. Evaluasi Model

Evaluasi model adalah langkah penting dalam proses pengembangan model pembelajaran mesin, termasuk Neural Network, untuk memastikan bahwa model yang dibangun memiliki kinerja yang memadai dan dapat diandalkan. Dalam penelitian ini, evaluasi model dilakukan menggunakan berbagai metrik evaluasi seperti akurasi, presisi, recall, dan F1-score untuk memberikan gambaran yang komprehensif mengenai kinerja model dalam memprediksi kegagalan mesin. Setelah tahap pelatihan, model diuji pada data pengujian yang telah disisihkan sebelumnya. Akurasi digunakan sebagai metrik utama untuk mengukur seberapa sering model membuat prediksi yang benar. Presisi mengukur proporsi prediksi positif yang benar-benar positif, sementara recall mengukur proporsi kasus positif yang berhasil diidentifikasi oleh model. F1-score, yang merupakan rata-rata harmonis dari presisi dan recall, digunakan untuk memberikan gambaran keseimbangan antara kedua metrik tersebut.

Hasil evaluasi menunjukkan bahwa model Neural Network yang dikembangkan mampu mencapai akurasi yang sangat tinggi, yaitu 97.8%, dalam memprediksi kegagalan mesin. Model ini juga menunjukkan presisi dan recall yang tinggi pada sebagian besar kelas kegagalan, meskipun ada beberapa kelas minoritas yang memiliki performa lebih rendah. Hal ini menunjukkan bahwa meskipun model sangat efektif dalam memprediksi sebagian besar kelas kegagalan, masih ada ruang untuk perbaikan dalam menangani kelas-kelas yang jarang terjadi [19].

Confusion matrix digunakan untuk memberikan pandangan lebih mendalam mengenai distribusi prediksi model. Confusion matrix membantu dalam mengidentifikasi pola kesalahan yang dibuat oleh model, seperti false positives dan false negatives, yang dapat memberikan wawasan lebih lanjut mengenai area-area yang memerlukan perbaikan.

Evaluasi hyperparameter juga dilakukan untuk mengoptimalkan kinerja model. Hyperparameter seperti jumlah epoch, learning rate, batch size, dan dropout rate diuji dan disesuaikan berdasarkan kinerja pada data validasi. Proses tuning hyperparameter ini penting untuk memastikan bahwa model tidak hanya bekerja dengan baik pada data pelatihan tetapi juga dapat generalisasi dengan baik pada data yang tidak terlihat sebelumnya. Secara keseluruhan, hasil evaluasi menunjukkan bahwa model Neural Network yang dikembangkan dalam penelitian ini memiliki kinerja yang sangat baik dalam memprediksi kegagalan mesin. Evaluasi yang komprehensif menggunakan berbagai metrik dan teknik validasi memastikan bahwa model yang dihasilkan tidak hanya akurat tetapi juga andal dan siap digunakan dalam aplikasi pemeliharaan prediktif di industri [20].

E. Analisis Hasil dan Klasifikasi Model

Analisis hasil dan klasifikasi model merupakan tahap kritis dalam penelitian ini untuk memahami kinerja model Neural Network dalam memprediksi kegagalan mesin dan untuk membandingkannya dengan model pembandingan lainnya seperti k-Nearest Neighbor (k-NN), Logistic Regression, dan Support Vector Machine (SVM). Model Neural Network yang dikembangkan menunjukkan akurasi yang sangat tinggi, yaitu 97.8%, yang mencerminkan kemampuan model dalam mengenali pola-pola kompleks dalam data operasional mesin. Evaluasi menggunakan metrik presisi, recall, dan F1-score menunjukkan bahwa model ini tidak hanya akurat tetapi juga memiliki kemampuan yang baik dalam mendeteksi kelas-kelas kegagalan yang berbeda, meskipun beberapa kelas minoritas masih memerlukan perbaikan.

Perbandingan dengan model pembandingan menunjukkan bahwa Neural Network unggul dalam hal akurasi dan kemampuan untuk menangani data dengan kompleksitas tinggi. Misalnya, k-NN, meskipun intuitif dan mudah diimplementasikan, menunjukkan sensitivitas yang tinggi terhadap noise dan kurang efektif dalam menangani data berdimensi tinggi. Logistic Regression, meskipun memberikan interpretasi yang mudah dan probabilistik, kurang mampu menangani hubungan non-linear yang kompleks dalam data. SVM, yang dikenal efektif dalam menangani data berdimensi tinggi, juga menunjukkan performa yang baik namun masih di bawah Neural Network dalam hal akurasi keseluruhan [21].

Selain itu, penggunaan Ensemble Learning dengan menggabungkan SVM dan Logistic Regression sebagai base learners dan Neural Network sebagai meta-learner menunjukkan peningkatan kinerja yang signifikan. Teknik stacking ini memanfaatkan keunggulan masing-masing model untuk menghasilkan prediksi yang lebih akurat dan andal. Hasil dari pendekatan Ensemble Learning ini menunjukkan bahwa kombinasi model-model ini dapat lebih baik dalam memprediksi kegagalan mesin dibandingkan dengan model individu [22].

Confusion matrix digunakan untuk menganalisis kesalahan prediksi yang dibuat oleh model. Hal ini membantu dalam mengidentifikasi false positives dan false negatives, yang memberikan wawasan lebih dalam mengenai area yang memerlukan perbaikan. Misalnya, model mungkin lebih sering salah mengklasifikasikan kelas kegagalan tertentu, yang mengindikasikan perlunya peningkatan dalam penanganan kelas tersebut melalui teknik seperti penyeimbangan data atau penambahan fitur yang lebih relevan.

Secara keseluruhan, hasil analisis menunjukkan bahwa Neural Network adalah alat yang sangat efektif dan efisien untuk aplikasi pemeliharaan prediktif. Model ini tidak hanya memberikan hasil yang sangat akurat tetapi juga mampu menangani kompleksitas dan variabilitas data operasional mesin. Penggunaan teknik Ensemble Learning lebih lanjut meningkatkan kinerja model, menjadikannya solusi yang sangat kuat untuk meningkatkan keandalan dan efisiensi operasional di industri. Penelitian ini memberikan bukti kuat bahwa integrasi berbagai teknik pembelajaran mesin dapat menghasilkan sistem prediksi yang sangat canggih dan efektif.

4. KESIMPULAN

Penelitian ini mengembangkan model Neural Network untuk prediksi kegagalan mesin berbasis parameter operasional dan menunjukkan kinerja yang sangat baik dengan akurasi mencapai 97,8%. Hasil ini menegaskan kemampuan Neural Network dalam menangkap pola non-linear dan kompleks yang sulit diidentifikasi oleh metode konvensional. Penerapan teknik prapemrosesan, seperti pengkodean data kategorikal, normalisasi, dan random oversampling, terbukti efektif dalam meningkatkan kualitas data serta kinerja model, khususnya pada kondisi dataset yang tidak seimbang. Selain itu, hasil evaluasi menunjukkan bahwa Neural Network memiliki performa yang lebih unggul dibandingkan metode pembandingan seperti k-Nearest Neighbor, Logistic Regression, dan Support Vector Machine dalam hal akurasi dan kemampuan generalisasi.

Kontribusi utama penelitian ini terletak pada penerapan pendekatan ensemble learning yang menggabungkan SVM dan Logistic Regression sebagai base learners dengan Neural Network sebagai meta-learner, yang terbukti meningkatkan kinerja prediksi secara signifikan. Temuan ini memperkuat bukti empiris bahwa integrasi beberapa model mampu menghasilkan prediksi yang lebih robust pada data operasional mesin yang kompleks. Secara ilmiah, penelitian ini memberikan kontribusi dalam pengembangan metode pemeliharaan prediktif berbasis pembelajaran mesin, khususnya dalam meningkatkan akurasi dan keandalan model pada kondisi data tidak seimbang, serta menunjukkan pentingnya optimasi prapemrosesan dan strategi pemodelan dalam meningkatkan performa klasifikasi kegagalan mesin.

DAFTAR PUSTAKA

- [1] T. Brown, R. Martinez, and L. Chen, "Normalization techniques in machine learning models for industrial data," *J. Comput. Sci.*, vol. 25, no. 3, pp. 567-579, 2019.
- [2] T. Zonta, C. A. da Costa, R. da Rosa Righi, M. J. de Lima, E. S. da Trindade, and G. P. Li, "Predictive maintenance in the Industry 4.0: A systematic literature review," *Comput. Ind. Eng.*, vol. 150, p. 106889, 2020.
- [3] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic minority over-sampling technique," *J. Artif. Intell. Res.*, vol. 16, pp. 321-357, 2002.
- [4] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [5] T. P. Carvalho, F. A. A. M. N. Soares, R. Vita, R. D. P. Francisco, J. P. Basto, and S. G. S. Alcala, "A systematic literature review of machine learning methods applied to predictive maintenance," *Comput. Ind. Eng.*, vol. 137, p. 106024, 2019.
- [6] Y. Lei, B. Yang, X. Jiang, F. Jia, N. Li, and A. K. Nandi, "Applications of machine learning to machine fault diagnosis: A review and roadmap," *Mech. Syst. Signal Process.*, vol. 138, p. 106587, 2020.
- [7] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, and R. X. Gao, "Deep learning and its applications to machine health monitoring," *Mech. Syst. Signal Process.*, vol. 115, pp. 213-237, 2019.
- [8] J. Smith and R. Johnson, "Impact of oversampling techniques on machine learning models for imbalanced datasets," *J. Data Sci.*, vol. 18, no. 2, pp. 134-145, 2020.
- [9] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA: MIT Press, 2016.
- [10] D. P. Kingma and J. L. Ba, "Adam: A method for stochastic optimization," in *Proc. 3rd Int. Conf. Learn. Represent. (ICLR)*, San Diego, CA, USA, 2015.
- [11] Y. Zhang, X. Liu, Z. Wang, and K. Chen, "Data cleaning and preprocessing techniques for machine learning," *IEEE Trans. Knowl. Data Eng.*, vol. 30, no. 1, pp. 60-73, 2018.
- [12] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Netw.*, vol. 61, pp. 85-117, 2015.
- [13] T. M. Cover and P. E. Hart, "Nearest neighbor pattern classification," *IEEE Trans. Inf. Theory*, vol. 13, no. 1, pp. 21-27, 1967.

- [14] T. G. Dietterich, "Ensemble methods in machine learning," in Proc. Int. Workshop Multiple Classifier Syst., vol. 1857, pp. 1-15, 2000.
- [15] D. W. Hosmer, S. Lemeshow, and R. X. Sturdivant, Applied Logistic Regression, 3rd ed. Hoboken, NJ: Wiley, 2013.
- [16] C. Cortes and V. Vapnik, "Support-vector networks," Mach. Learn., vol. 20, no. 3, pp. 273-297, 1995.
- [17] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," J. Mach. Learn. Res., vol. 15, pp. 1929-1958, 2014.
- [18] Z. Chen, C. Li, and R. Sanchez, "Gearbox fault identification and classification with convolutional neural networks," Shock Vib., vol. 2015, pp. 1-10, 2015.
- [19] M. Azamfar, J. Singh, I. Bravo-Imaz, and J. Lee, "Multisensor data fusion for gearbox fault diagnosis using 2-D convolutional neural network and motor current signature analysis," Mech. Syst. Signal Process., vol. 144, p. 106861, 2020.
- [20] K. Peng, Z. Tian, J. Dong, C. W. de Silva, and C. Liu, "A deep learning-based remaining useful life prediction approach for bearings," Neural Comput. Appl., vol. 33, pp. 5425-5439, 2021.
- [21] W. Wuest, C. Irgens, and K.-D. Thoben, "An approach to monitoring quality in manufacturing using supervised machine learning on product state data," J. Intell. Manuf., vol. 27, no. 5, pp. 1167-1186, 2016.
- [22] C. Zhang, P. Lim, A. K. Qin, and K. C. Tan, "Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics," IEEE Trans. Neural Netw. Learn. Syst., vol. 28, no. 10, pp. 2306-2318, 2017.