

IMPLEMENTASI ARTIFICIAL NEURAL NETWORK UNTUK PREDIKSI PELAKSANAAN PEMELIHARAAN HOTEL DI YOGYAKARTA

¹⁾Bagus Gilang Pratama, ²⁾Sely Novita Sari, ³⁾Rizal Maulana

¹⁾Program Studi Teknik Elektro, Fakultas Teknik dan Perencanaan, Institut Teknologi Nasional Yogyakarta

^{2,3)} Program Studi Teknik Sipil, Fakultas Teknik dan Perencanaan, Institut Teknologi Nasional Yogyakarta

¹⁾bagusgilangp@itny.ac.id, ²⁾sely.novita@itny.ac.id, ³⁾rizalmaulana@itny.ac.id

INFO ARTIKEL

Riwayat Artikel :

Diterima : 11 Jul 2025

Disetujui : 10 Oktober 2025

Kata Kunci :

Artificial Neural Network, Pemeliharaan Hotel, Prediksi Kelayakan, Machine Learning

ABSTRAK

Industri perhotelan di Yogyakarta menghadapi tantangan dalam pemeliharaan fasilitas yang efisien dan berbasis kondisi aktual. Penelitian ini mengembangkan model Artificial Neural Network (ANN) untuk mengidentifikasi jenis pemeliharaan hotel secara akurat. Menggunakan pendekatan kuantitatif dengan data dari 175 responden, model dilatih menggunakan arsitektur multilayer perceptron dan data yang dinormalisasi dengan Min-Max Scaler. hasilnya menunjukkan performa klasifikasi yang sangat baik terhadap lima kategori kelayakan pemeliharaan hotel. Model berhasil memprediksi 9 data kelas Sangat Tidak Layak secara akurat, 11 dari 13 data kelas Tidak Layak dengan 2 kesalahan minor, serta 15 dari 16 data kelas Cukup Layak dengan hanya 1 kesalahan. Untuk kelas Layak, model mengklasifikasikan 9 data secara tepat, dan pada kelas Sangat Layak, seluruh 6 data diprediksi dengan akurasi sempurna tanpa kesalahan. Temuan ini menegaskan efektivitas ANN dalam pemeliharaan prediktif dan potensinya untuk diintegrasikan ke sistem IoT, meskipun masih perlu pengembangan terkait data real-time dan ketidakseimbangan kelas.

ARTICLE INFO

Article History :

Received : Jul 11, 2025

Accepted : Oct 10, 2025

Keywords:

Artificial Neural Network, Hotel Maintenance, Feasibility Prediction, Machine Learning

ABSTRACT

The hospitality industry in Yogyakarta faces challenges in maintaining facilities efficiently and based on actual conditions. This study developed an Artificial Neural Network (ANN) model to accurately identify the types of hotel maintenance required. Using a quantitative approach with data from 175 respondents, the model was trained with a multilayer perceptron architecture and normalized using the Min-Max Scaler method. The results demonstrated strong classification performance across five categories of maintenance feasibility. The model accurately predicted 9 cases in the "Very Unfeasible" class, 11 out of 13 in the "Unfeasible" class with only 2 minor misclassifications, and 15 out of 16 in the "Fairly Feasible" class with a single error. It also correctly classified all 9 cases in the "Feasible" class and achieved perfect accuracy on all 6 cases in the "Very Feasible" class. These findings confirm the effectiveness of ANN in predictive maintenance and highlight its potential for integration into IoT-based systems, though further development is needed to address limitations related to real-time data and class imbalance.

1. PENDAHULUAN

Industri perhotelan di Yogyakarta memegang peran strategis dalam menunjang sektor pariwisata, yang menjadi salah satu penggerak utama ekonomi daerah. Dalam kompetisi yang semakin ketat, kualitas fasilitas fisik hotel menjadi salah satu faktor kunci yang memengaruhi kepuasan pelanggan dan citra bisnis. Oleh karena itu, sistem pemeliharaan dan perawatan bangunan hotel perlu dirancang secara efisien dan adaptif. Pemeliharaan yang dilakukan secara reaktif atau berbasis jadwal tetap seringkali tidak mampu mengantisipasi kebutuhan aktual fasilitas, menyebabkan inefisiensi operasional dan peningkatan biaya yang tidak perlu.

Artificial Neural Network (ANN) merupakan salah satu pendekatan dalam kecerdasan buatan yang mampu mempelajari pola kompleks dari data historis. ANN dapat digunakan untuk membangun sistem prediktif, yang memungkinkan manajer fasilitas hotel menentukan waktu dan jenis perawatan secara lebih akurat berdasarkan kondisi riil. Pemanfaatan ANN dalam konteks ini menjadi langkah potensial untuk beralih dari pendekatan preventif menuju strategi predictive maintenance yang lebih cerdas dan hemat sumber daya.

Masalah utama yang dihadapi oleh banyak hotel di Yogyakarta adalah rendahnya efektivitas sistem pemeliharaan, yang masih didominasi oleh metode tradisional baik itu reaktif (*breakdown maintenance*) maupun berbasis jadwal rutin (*preventive maintenance*). Keduanya memiliki kelemahan mendasar yaitu metode reaktif menyebabkan *downtime* dan biaya tinggi, sedangkan metode preventif cenderung *overmaintenance* karena tidak mempertimbangkan kondisi aktual fasilitas.

Sebagai alternatif, pendekatan prediktif berbasis data dapat digunakan untuk meminimalkan inefisiensi tersebut. ANN, dengan kemampuannya dalam memodelkan hubungan non-linear antar variabel, menjadi solusi potensial untuk memprediksi kebutuhan pemeliharaan berdasarkan variabel-variabel seperti usia bangunan, tingkat penggunaan, dan kondisi lingkungan.

Penerapan *Artificial Neural Networks* (ANN) dalam strategi pemeliharaan prediktif

(*Predictive Maintenance/PdM*) telah menunjukkan efektivitas tinggi dalam berbagai sektor industri. Model hibrida seperti kombinasi *Gated Recurrent Units* (GRU) dan *Transformer Encoder* telah berhasil digunakan untuk memprediksi kerusakan alat berat berdasarkan data sensor, seperti suhu, torsi, dan kecepatan rotasi, sehingga memungkinkan transisi dari pemeliharaan berbasis waktu ke pemeliharaan berbasis kondisi (Tanyıldız, Batur Şahin and Batur Dinler, 2024). Selain itu, pendekatan berbasis jaringan saraf konvolusional dan memori jangka panjang (CNN-LSTM) juga terbukti lebih akurat dan efisien dalam memproses data multivariat, dengan skor F-Score yang lebih tinggi dibanding model LSTM standar (Nasser and AL-Khazraji, 2022). Pendekatan serupa telah digunakan dalam memprediksi masa guna sistem dan peralatan industri, memperlihatkan potensi tinggi dalam mengoptimalkan jadwal perawatan dan mengurangi waktu henti (Wang, Zhu and Zhao, 2024).

Dalam konteks manajemen hotel, penerapan teknologi jaringan saraf masih tergolong terbatas. Studi yang memanfaatkan *Convolutional Neural Network* (CNN) untuk klasifikasi kebersihan kamar menunjukkan potensi ANN dalam aplikasi operasional hotel, meskipun belum menyasar langsung aspek pemeliharaan teknis (Dharmali, Lioner and Susilo, 2021). Beberapa penelitian lain juga mulai mengeksplorasi aplikasi *machine learning* dalam pemeliharaan infrastruktur seperti jalan dan jembatan, misalnya melalui penggunaan *Principal Component Analysis* (PCA) untuk menyederhanakan variabel-variabel penentu prioritas pemeliharaan (Musril *et al.*, 2023). Sementara itu, studi di tingkat lokal oleh (Sari *et al.*, 2024) menunjukkan bahwa implementasi pemeliharaan dan perawatan bangunan hotel di Sleman Yogyakarta masih rendah, dengan tingkat pelaksanaan yang hanya mencapai 55,57% untuk pemeliharaan dan 63,39% untuk perawatan. Studi tersebut menyoroti belum adanya sistem prediktif yang diterapkan dan kurangnya integrasi dengan regulasi nasional seperti Peraturan Menteri PUPR No. 24/PRT/M/2008 (Sari and Triwuryanto, 2021).

Berdasarkan perkembangan penelitian tersebut, terlihat bahwa sebagian besar

pendekatan ANN dalam pemeliharaan masih berfokus pada sektor industri berat atau infrastruktur berskala besar. Belum banyak penelitian yang secara khusus mengembangkan model ANN untuk konteks fasilitas hotel, yang memiliki karakteristik operasional unik seperti intensitas penggunaan harian yang tinggi, fluktuasi tamu, dan kebutuhan layanan tanpa gangguan. Selain itu, model yang ada umumnya masih bersifat eksperimental dan belum diintegrasikan ke dalam sistem pendukung keputusan yang aplikatif bagi manajemen hotel.

Kesenjangan yang diidentifikasi dalam penelitian ini mencakup tiga aspek utama. Pertama, belum tersedia model ANN berbasis data lokal yang dirancang khusus untuk memprediksi kebutuhan pemeliharaan fasilitas hotel di wilayah pariwisata seperti Yogyakarta. Kedua, penelitian sebelumnya belum menggabungkan model prediktif ANN dengan sistem pengambilan keputusan yang dapat digunakan langsung oleh pengelola hotel dalam perencanaan dan eksekusi pemeliharaan. Ketiga, sangat sedikit penelitian yang mengkaji performa ANN dalam konteks operasional hotel yang dinamis, berbeda dari sistem industri yang lebih stabil dan terstandar.

Berdasarkan kesenjangan yang telah diidentifikasi Penelitian ini bertujuan untuk mengembangkan dan mengimplementasikan model *Artificial Neural Network* (ANN) yang mampu mengidentifikasi jenis pemeliharaan fasilitas hotel secara akurat dan efisien. Model ini diharapkan dapat menjadi dasar dalam sistem pendukung keputusan pemeliharaan hotel yang berbasis data lokal.

Urgensi penelitian ini didorong oleh kebutuhan industri perhotelan untuk meningkatkan efisiensi operasional di tengah tuntutan pasar yang semakin kompetitif. Implementasi model ANN yang tepat dapat menjadi solusi untuk mengurangi biaya, meminimalkan gangguan operasional, serta meningkatkan kepuasan pelanggan melalui fasilitas yang lebih terawat. Selain itu, penelitian ini mendukung pengembangan teknologi cerdas dalam manajemen fasilitas, yang sejalan dengan arah transformasi digital industri perhotelan.

2. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan desain deskriptif-eksplanatori untuk membangun dan menguji model Artificial Neural Network (ANN) dalam memprediksi kebutuhan pemeliharaan fasilitas hotel secara lebih akurat dan berbasis data. Populasi penelitian mencakup seluruh hotel di wilayah Daerah Istimewa Yogyakarta, dengan total 175 responden dari 48 hotel yang dipilih melalui teknik purposive sampling. Kriteria responden mencakup pengalaman minimal dua tahun di bidang pemeliharaan serta keterlibatan langsung dalam sistem dokumentasi fasilitas hotel.

Data dikumpulkan melalui kuesioner dan wawancara terstruktur yang mengacu pada indikator teknis dari regulasi Permen PUPR No. 24/PRT/M/2008 serta studi literatur terkait. Instrumen mengukur tingkat pelaksanaan pemeliharaan rutin dan berkala berdasarkan frekuensi pelaksanaan kegiatan di lapangan ((Sari and Triwuryanto, 2021; Musril *et al.*, 2023; Sari *et al.*, 2024)). Frekuensi pelaksanaan pemeliharaan rutin dan berkala mengacu pada seberapa sering kegiatan perawatan dilakukan terhadap fasilitas hotel dalam periode waktu tertentu (misalnya per minggu, per bulan, per triwulan, atau per tahun), yang dilakukan secara terjadwal.



Gambar 1. Prosedur Tahapan Penelitian
Untuk memudahkan interpretasi hasil analisis kuantitatif dan mendukung proses pengambilan keputusan, digunakan standar kriteria kelayakan yang mengklasifikasikan hasil evaluasi ke dalam lima kategori berbasis persentase skor. Kriteria ini berguna untuk menilai sejauh mana suatu sistem atau proses dalam hal ini, sistem pemeliharaan dan perawatan hotel dapat dianggap layak atau tidak berdasarkan tingkat pelaksanaannya di lapangan. Standar ini digunakan untuk menilai tingkat kelayakan berdasarkan persentase skor hasil evaluasi (Sari *et al.*, 2024). Skor diklasifikasikan menjadi lima kategori:

- a. < 21% = **Sangat Tidak Layak** (Kelas 0)
- b. 21–40% = **Tidak Layak** (Kelas 1)
- c. 40–60% = **Cukup Layak** (Kelas 2)
- d. 60–80% = **Layak** (Kelas 3)
- e. 80–100% = **Sangat Layak** (Kelas 4)

Kategori ini mempermudah interpretasi data kuantitatif menjadi penilaian kualitatif dalam pengambilan keputusan.

Penelitian ini menggunakan pendekatan kuantitatif dengan desain deskriptif-eksplanatori, yang dirancang untuk mengembangkan dan menguji model Artificial Neural Network (ANN) dalam memprediksi kebutuhan pemeliharaan fasilitas hotel secara akurat dan aplikatif. Prosedur penelitian dilaksanakan secara sistematis melalui lima tahap utama yaitu (1) persiapan instrumen dan perizinan, termasuk uji validitas dan reliabilitas kuesioner; (2) pengumpulan data primer melalui distribusi kuesioner serta data sekunder dari dokumentasi pemeliharaan hotel; (3) prapemrosesan data yang mencakup pembersihan, normalisasi (Min-Max Scaler), dan pengodean variabel; (4) pengembangan dan pelatihan model ANN dengan arsitektur multilayer perceptron; dan (5) evaluasi performa model menggunakan metrik MSE, RMSE, dan akurasi klasifikasi.

Rumus perhitungan untuk masing-masing matrik ini disajikan dalam Algorit berikut (Krenek *et al.*, 2016; Sari, Pratama and Prastowo, 2024).

$$\text{Accuracy} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

$$\text{Precision} = \frac{TP}{(TP + FP)} \quad (2)$$

$$\text{Recall} = \frac{TP}{(TP + FN)} \quad (3)$$

$$\text{F1 Score} = \frac{2 \times (\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (4)$$

$$\text{Specificity} = \frac{TN}{(TN + FP)} \quad (5)$$

$$\text{False Positive Rate} = \frac{FP}{(FP + TN)} \quad (6)$$

Dimana TP = True Positive, TN = True Negative, FP = False Positive, dan FN = False Negative.

Data dibagi dalam proporsi 80% untuk pelatihan dan 20% untuk pengujian guna menghindari overfitting. Meski data dari 175 responden memberikan gambaran awal yang representatif, keterbatasan pada data persepsi subjektif dan tidak adanya data sensor real-time menjadi perhatian utama. Oleh karena itu, untuk validasi dan generalisasi yang lebih kuat, perlu dilakukan pengembangan lebih lanjut dengan integrasi data aktual berbasis sensor (IoT) serta

perluasan jumlah dan sumber data dalam skala yang lebih besar dan beragam.

Meskipun model menunjukkan performa tinggi, penelitian ini menyadari keterbatasan pada volume data dan sifat subjektif kuesioner. Oleh karena itu, perluasan cakupan data dan integrasi dengan data real-time berbasis sensor (IoT) direkomendasikan sebagai langkah lanjutan untuk meningkatkan keakuratan dan keandalan model dalam kondisi operasional aktual.

3. HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan sebuah model prediksi untuk menilai kelayakan pelaksanaan pemeliharaan dan perawatan hotel di Yogyakarta dengan pendekatan Artificial Neural Network (ANN). Data yang digunakan dalam model ini berasal dari 175 responden yang tersebar di sekitar 45 hotel di wilayah Yogyakarta. Variabel input yang dianalisis berjumlah 11 indikator, mencakup aspek pemeliharaan dan perawatan pada bidang arsitektur, struktur, sistem mekanikal dan elektrikal, ruang luar, serta tata graha. Seluruh data telah dinormalisasi menggunakan metode Min-Max Scaler guna memastikan keseragaman skala antarvariabel dan meningkatkan stabilitas proses pelatihan model.

Hasil pengolahan data menunjukkan bahwa tingkat implementasi sistem pemeliharaan dan perawatan di hotel-hotel tersebut cukup bervariasi. Penilaian kelayakan dilakukan dengan menghitung persentase skor dari total item pemeliharaan yang seharusnya dijalankan. Persentase tersebut kemudian diklasifikasikan ke dalam lima kategori, yaitu kurang dari 21 persen dinilai sebagai sangat tidak layak (kelas 0), 21 hingga 40 persen sebagai tidak layak (kelas 1), 40 hingga 60 persen sebagai cukup layak (kelas 2), 60 hingga 80 persen sebagai layak (kelas 3), dan 80 hingga 100 persen dikategorikan sebagai sangat layak (kelas 4) (Sari *et al.*, 2024). Skema klasifikasi ini menjadi acuan utama dalam proses pelabelan data dan pemodelan prediktif menggunakan ANN seperti dapat dilihat pada gambar 2.

Sebelum data dimasukkan ke dalam model ANN, dilakukan proses normalisasi data menggunakan metode *Min-Max Scaler*. Tujuan dari normalisasi ini adalah untuk mengubah

skala setiap variabel input ke dalam rentang nilai yang seragam, umumnya antara 0 dan 1. Langkah ini penting karena jaringan saraf sensitif terhadap skala numerik input, dan tanpa normalisasi, variabel dengan skala lebih besar dapat mendominasi proses pembelajaran model.

Data columns (total 12 columns):		
#	Column	Non-Null Count Dtype
0	PemeliharaanArsitektur	175 non-null float64
1	PerawatanArsitektur	175 non-null float64
2	PemeliharaanStruktur	175 non-null float64
3	PerawatanStruktur	175 non-null float64
4	PemeliharaanPerawatanMekanikal	175 non-null float64
5	PemeliharaanElektrikal	175 non-null float64
6	PerawatanElektrikal	175 non-null float64
7	PemeliharaanRuangLuar	175 non-null float64
8	PerawatanRuangLuar	175 non-null float64
9	PemeliharaanTataGraha	175 non-null float64
10	PerawatanTataGraha	175 non-null float64
11	Kelas	175 non-null float64

Gambar 2. Struktur Data Variabel Pemeliharaan dan Perawatan Hotel

Masing-masing fitur memiliki 175 nilai non-null bertipe float64, yang berarti seluruh data telah terisi lengkap tanpa ada nilai kosong, serta sudah dalam bentuk numerik kontinu. Ini menunjukkan bahwa dataset telah dipersiapkan dengan baik dan layak untuk digunakan dalam pelatihan model berbasis jaringan saraf tiruan. Dengan menggunakan *Min-Max Scaler*, semua nilai pada masing-masing kolom diubah proporsinya terhadap nilai minimum dan maksimum dalam kolom tersebut. Proses ini membantu mempercepat konvergensi model saat training, mengurangi risiko *vanishing gradient*, dan meningkatkan stabilitas serta performa model secara keseluruhan.

3.1. Parameter dan Arsitektur Model ANN

Model prediktif dalam penelitian ini dibangun menggunakan arsitektur ANN dengan pendekatan *feedforward* berlapis (*multilayer perceptron*). Model ini dirancang untuk mengklasifikasikan tingkat kelayakan pemeliharaan dan perawatan hotel berdasarkan 11 variabel input yang telah dinormalisasi sebelumnya.

Struktur Dataset

Data dibagi ke dalam tiga kelompok yaitu 50% untuk pelatihan (*training*), 20% untuk validasi, dan 30% untuk pengujian (*testing*). Proporsi ini digunakan untuk memastikan model dapat belajar secara optimal, divalidasi selama proses training, dan diuji untuk mengukur generalisasi.

Parameter ANN

Dataset

- Training = 50%;
- Validation = 20%;
- Test = 30%

Optimizer = SGD

Layer

- Input = 11;
- Hidden Layer 1 = 28 Node;
- Hidden Layer 2 = 44
- Output = 5;
- Epoch = 400;
- Learning rate=0,001
- Batch Size = 4

Activation = Relu & Softmax

Metrics = accuracy

Loss = sparse categorical crossentropy

Model: "sequential_1"		
Layer (type)	Output Shape	Param #
dense_4 (Dense)	(None, 11)	132
dense_5 (Dense)	(None, 28)	336
dense_6 (Dense)	(None, 44)	1276
dense_7 (Dense)	(None, 5)	225

Gambar 3. Struktur dan Parameter Model ANN untuk Klasifikasi Kelayakan Pemeliharaan Hotel

Parameter Model

Model ANN yang digunakan dalam penelitian ini dirancang dengan struktur *multilayer perceptron* yang terdiri dari empat lapisan utama. Jumlah neuron pada input layer adalah 11, yang sesuai dengan jumlah variabel fitur dari data pemeliharaan dan perawatan hotel. Model ini memiliki dua *hidden layer*, masing-masing terdiri dari 28 dan 44 node. Sementara itu, *output layer* terdiri dari 5 node yang merepresentasikan lima kelas kelayakan, yaitu dari kelas 0 (sangat tidak layak) hingga kelas 4 (sangat layak). Aktivasi yang digunakan pada *hidden layer* adalah fungsi ReLU (*Rectified Linear Unit*), sedangkan pada *output layer* digunakan fungsi aktivasi Softmax, yang umum digunakan dalam klasifikasi multikelas karena kemampuannya menghasilkan distribusi probabilitas

Optimasi dan Pelatihan

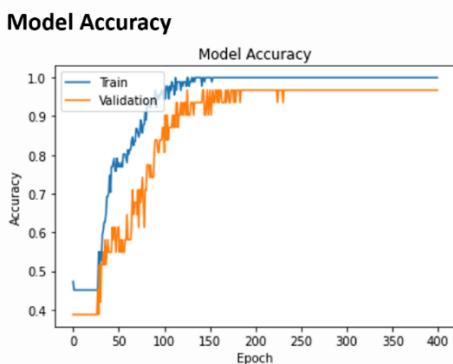
Model dilatih menggunakan algoritma *Stochastic Gradient Descent* (SGD) dengan learning rate sebesar 0,001, dijalankan selama 400 epoch dan batch size 4 untuk menjaga keseimbangan antara kecepatan pelatihan dan kemampuan generalisasi model. Fungsi loss yang digunakan adalah sparse categorical crossentropy, yang sesuai untuk data target berupa label numerik diskret dan mendukung klasifikasi multikelas secara efisien. Arsitektur model terdiri dari empat lapisan dense (*fully connected*), termasuk dua *hidden layer* dengan jumlah node yang disesuaikan untuk menangkap kompleksitas hubungan antarvariabel input. Konfigurasi ini dirancang untuk memaksimalkan akurasi prediksi kelas kelayakan pemeliharaan dan perawatan hotel sambil menjaga kestabilan proses pelatihan. Visualisasi struktur model ditampilkan dalam Gambar 3 sebagai keluaran dari pemrograman

Python, menggambarkan susunan dan jumlah parameter pada setiap lapisan.

3.2. Model Accuracy

Pada awal pelatihan (epoch < 50), model menunjukkan peningkatan akurasi yang signifikan baik pada data pelatihan maupun validasi, dengan fluktuasi yang wajar. Seiring dengan proses pelatihan yang berlanjut, akurasi pelatihan meningkat mendekati 100% dan mencapai ketebalan. Kurva akurasi validasi juga mengalami kenaikan dan mulai stabil pada kisaran akurasi di atas 95% setelah sekitar epoch ke-150. Hasil ini menunjukkan bahwa model ANN berhasil belajar dari data pelatihan secara efektif tanpa mengalami overfitting yang signifikan, karena akurasi validasi tetap tinggi dan sejalan dengan akurasi pelatihan. Performa ini mencerminkan bahwa model mampu menggeneralisasi dengan baik terhadap data baru yang belum pernah dilihat sebelumnya.

Gambar 4 menunjukkan performa akurasi model ANN selama proses pelatihan (*training*) dan validasi hingga 400 epoch. Dua garis dalam grafik merepresentasikan kurva akurasi untuk data pelatihan (biru) dan data validasi (oranye) seiring bertambahnya jumlah epoch.



Gambar 4. Grafik Akurasi Model ANN Selama Proses Pelatihan dan Validasi

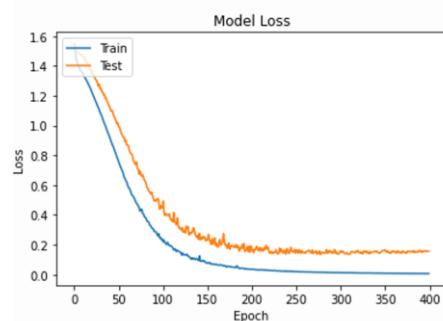
3.3. Model Loss

Grafik nilai loss (kerugian) dari model ANN selama proses pelatihan dan pengujian terhadap jumlah epoch. Grafik ini menampilkan dua kurva yaitu satu untuk data pelatihan (*train*) dan satu lagi untuk data pengujian (*test*) seperti yang ditunjukkan pada gambar 5.

Terlihat bahwa nilai loss untuk data pelatihan menurun secara konsisten mendekati nol, menunjukkan bahwa model berhasil mempelajari pola dari data dengan baik selama proses pelatihan. Sementara itu, nilai loss pada

data pengujian juga mengalami penurunan yang signifikan hingga sekitar epoch ke-150, lalu mulai stabil dan sedikit berfluktuasi.

Model Loss



Gambar 5. Grafik Loss Model ANN pada Data Pelatihan dan Pengujian

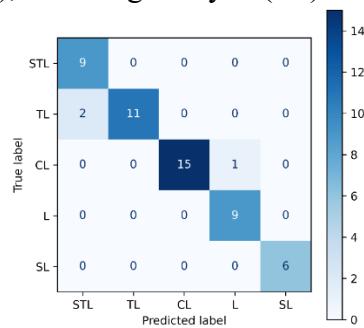
Perbedaan antara garis *train loss* dan *test loss* di bagian akhir menunjukkan adanya sedikit *gap* atau jarak, namun tidak ekstrem. Hal ini menandakan bahwa model tidak mengalami overfitting yang parah, dan tetap mampu menjaga kemampuan generalisasi terhadap data baru yang belum pernah dilihat. Secara keseluruhan, grafik ini memperkuat bahwa model ANN yang digunakan telah terlatih secara efektif dan cukup stabil untuk digunakan dalam memprediksi tingkat kelayakan pemeliharaan hotel berdasarkan data historis dari 175 responden.

3.4. Confusion Matrix Model ANN

Untuk mengevaluasi performa klasifikasi model ANN dalam memprediksi tingkat kelayakan pemeliharaan dan perawatan hotel, digunakan *confusion matrix* sebagai alat analisis. *Confusion matrix* memberikan gambaran detail mengenai distribusi prediksi model terhadap masing-masing kelas yang telah ditentukan, sehingga dapat diketahui seberapa akurat model dalam mengklasifikasikan data ke dalam lima kategori kelayakan yang berbeda. Evaluasi ini menjadi penting untuk memastikan bahwa model tidak hanya unggul dalam akurasi keseluruhan, tetapi juga mampu membedakan secara tepat antara kategori kelayakan yang serupa.

Gambar 5 menampilkan *confusion matrix* hasil prediksi model ANN terhadap data uji, yang terdiri dari lima kelas tingkat kelayakan pemeliharaan hotel yaitu Sangat Tidak Layak

(STL), Tidak Layak (TL), Cukup Layak (CL), Layak (L), dan Sangat Layak (SL).



Gambar 5. Confusion Matrix Model ANN pada Klasifikasi Kelayakan Pemeliharaan Hotel

Matriks ini menggambarkan seberapa baik model mengenali dan mengklasifikasikan tiap kategori dengan benar. Hasil analisis yang didapatkan, model berhasil memprediksi 9 data kelas STL secara akurat. Untuk kelas TL, terdapat 11 prediksi yang benar dan 2 prediksi yang salah (diklasifikasikan sebagai STL). Pada kelas CL, model memprediksi dengan benar sebanyak 15 data dan 1 data salah diklasifikasikan ke dalam kelas L. Sementara itu, kelas L memiliki 9 prediksi yang akurat dan kelas SL menunjukkan hasil yang sempurna dengan 6 prediksi benar tanpa kesalahan klasifikasi.

Confusion matrix ini menunjukkan bahwa model memiliki tingkat akurasi klasifikasi yang cukup tinggi, dengan kesalahan klasifikasi yang minim dan tidak menyebar luas ke kelas yang tidak relevan. Hal ini menandakan bahwa model ANN mampu membedakan pola-pola antar kelas kelayakan dengan baik, serta memiliki performa yang stabil dalam tugas klasifikasi multi-kelas pada konteks pemeliharaan dan perawatan hotel di Yogyakarta.

3.5. Evaluasi Performa Model ANN

Hasil evaluasi performa model Artificial Neural Network (ANN) menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik dalam memprediksi kelayakan pemeliharaan hotel. Nilai recall untuk sebagian besar kelas mencapai angka maksimal, seperti pada kelas Sangat Tidak Layak (STL), Layak (L), dan Sangat Layak (SL) yang masing-masing memperoleh skor 1.0000. Hal ini menunjukkan bahwa model mampu mengenali seluruh data aktual dari kelas-kelas tersebut tanpa ada yang

terlewati. Kelas Tidak Layak (TL) memiliki nilai recall sebesar 0.8462 dan kelas Cukup Layak (CL) sebesar 0.9375, yang masih berada dalam rentang tinggi, meskipun menunjukkan adanya beberapa kasus kesalahan klasifikasi minor.

Tabel 1. Indikator Performa

Class Name	Pre cisi on	1- Precisi on	Recall	False Negative Rate	F1 Score	Specific ity (TNR)	False Positiv e Rate (FPR)
STL	0.81	0.182	1	0	0.9	0.955	0.045
TL	1	0	0.8	0.154	0.917	1	0
CL	1	0	0.938	0.063	0.968	1	0
L	0.9	0.1	1	0	0.947	0.977	0.023
SL	1	0	1	0	1	1	0

Dari sisi specificity atau True Negative Rate (TNR), model juga menunjukkan performa yang sangat baik. Hampir semua kelas mencatat nilai TNR sebesar 1.0000, menandakan bahwa model tidak keliru mengklasifikasikan data dari kelas lain sebagai kelas tersebut. Hanya pada kelas Layak (L) ditemukan nilai TNR sebesar 0.9773, yang tetap berada dalam kategori sangat baik. Hal ini mengindikasikan kemampuan model untuk meminimalisir false positive secara konsisten.

Tabel 2. Matrik Evaluasi Model

Metric	Accuracy	Misclassificat ion Rate	Macro-F1	Weighted- F1
Value	0.9434	0.0566	0.9464	0.9439

Secara keseluruhan, nilai accuracy model mencapai 0.9434 atau setara dengan 94,34%, sementara misclassification rate-nya hanya 0.0566 (5,66%). Nilai Macro-F1 dan Weighted-F1 yang masing-masing sebesar 0.9464 dan 0.9439 turut memperkuat bahwa model memiliki keseimbangan performa dalam klasifikasi multikelas, baik dari sisi presisi maupun recall. Temuan ini menegaskan bahwa model ANN yang dikembangkan sangat andal, mampu menggeneralisasi dengan baik terhadap data baru, serta layak diimplementasikan dalam sistem pengambilan keputusan prediktif di sektor perhotelan.

3.6. Pembahasan

Hasil penelitian menunjukkan bahwa model ANN yang dibangun memiliki akurasi tinggi dalam klasifikasi kelayakan dan tingkat kesalahan yang rendah, membuktikan

kemampuannya dalam memahami pola kompleks dari berbagai jenis data pemeliharaan hotel. Keunggulan ini memperkuat argumen bahwa ANN sangat relevan untuk diterapkan dalam strategi pemeliharaan prediktif. Namun demikian, perlu dicatat bahwa data yang digunakan dalam penelitian ini masih terbatas pada 175 responden dari kuesioner manual. Data berbasis persepsi seperti ini rentan terhadap bias subjektif, yang dapat memengaruhi reliabilitas model terutama pada konteks operasional nyata. Pendekatan ini belum sepenuhnya menangkap kondisi teknis aktual fasilitas hotel secara objektif.

Distribusi kelas dalam dataset menunjukkan ketidakseimbangan minor, seperti jumlah data pada kelas "Sangat Layak" yang hanya mencakup 6 entri. Meskipun model menunjukkan performa klasifikasi yang tinggi, ketimpangan ini berpotensi mempengaruhi stabilitas model dalam skenario data nyata yang lebih kompleks. Untuk penelitian mendatang, disarankan menerapkan teknik balancing seperti SMOTE atau class weighting.

Proses normalisasi data menggunakan *Min-Max Scaler* dan arsitektur jaringan yang terdiri dari dua hidden layer dengan fungsi aktivasi ReLU dan Softmax terbukti efektif dalam meminimalkan *overfitting* serta menjaga generalisasi model terhadap data baru. Hasil ini sejalan dengan studi yang mengembangkan pendekatan CNN-LSTM hibrida dan menemukan peningkatan signifikan dalam akurasi prediksi pemeliharaan (Nasser and AL-Khazraji, 2022). Hal ini juga diperkuat oleh temuan (Tanyıldız, Batur Şahin and Batur Dinler, 2024), yang menunjukkan bahwa ANN efektif dalam mendeteksi kesalahan operasional melalui analisis data sensor, serta mendukung strategi pemeliharaan berbasis kondisi.

Kontribusi utama dari penelitian ini adalah pengembangan model prediktif ANN dalam konteks industri perhotelan di Yogyakarta, sebuah sektor yang belum banyak disentuh dalam literatur kecerdasan buatan berbasis pemeliharaan prediktif. Dengan mengangkat data lokal dan karakteristik operasional hotel yang dinamis, penelitian ini memperluas cakupan pemanfaatan machine learning dari sektor industri berat ke sektor layanan. Lebih

lanjut, aplikasi praktis dari model ini dapat diarahkan pada integrasi sistem ke dalam dashboard interaktif atau platform manajemen fasilitas seperti CMMS. Dengan pengembangan lebih lanjut, model ini bisa dihubungkan dengan data sensor berbasis IoT untuk menangkap data real-time (misalnya temperatur, kelembaban, getaran), yang akan meningkatkan keakuratan prediksi sekaligus membuat sistem lebih adaptif dan otomatis.

Diskusi ini semakin diperkuat dengan merujuk pada studi-studi lain yang menganjurkan pendekatan terpadu dalam pemeliharaan prediktif. Kerangka kerja pemeliharaan prediktif berbasis AI yang menggabungkan pembelajaran mesin, pemrosesan bahasa alami, dan pembelajaran penguatan (*reinforcement learning*), menghasilkan peningkatan signifikan dalam efektivitas biaya dan keandalan sistem (Madhukar Dharavath, 2024). Pendekatan semacam ini menunjukkan potensi besar jika diterapkan secara holistik dalam sistem manajemen fasilitas hotel.

Demikian pula, keberhasilan penggunaan teknik *machine learning* dalam sistem pemeliharaan prediktif dengan akurasi hampir sempurna (99,9%), menegaskan kembali bahwa integrasi algoritma cerdas dapat sangat meningkatkan prediksi kebutuhan pemeliharaan (Abdulhameed *et al.*, 2024). Aplikasi ANN juga terbukti luas dalam konteks manajemen hotel dan manajemen energi dalam prediksi keuangan hotel semua menggarisbawahi fleksibilitas ANN dalam menangani berbagai jenis prediksi berbasis data (Contreras, Torres-Treviño and Torres, 2018; Wang and Chen, 2024).

Pada beberapa penelitian juga menekankan tantangan yang harus diperhatikan dengan menggarisbawahi pentingnya kualitas data, perlunya interpretabilitas model, dan penggunaan metrik evaluasi yang komprehensif seperti *confusion matrix*. Tantangan ini juga relevan dalam penelitian ini, terutama karena model masih bergantung pada data input manual dari kuesioner, tanpa dukungan data sensor real-time. Ketidakseimbangan jumlah data antar kelas juga berpotensi menimbulkan bias minor dalam proses klasifikasi (Reddy Voddi, 2023; Sari, Pratama and Ircham, 2024).

Dari sisi kontribusi praktis, model ANN dalam penelitian ini dapat dikembangkan lebih lanjut menjadi sistem pendukung keputusan berbasis web atau dashboard interaktif, yang memungkinkan pengelola hotel untuk merencanakan pemeliharaan secara efisien dan tepat waktu. Integrasi model dengan data sensor IoT seperti suhu, kelembaban, dan getaran akan lebih lanjut meningkatkan akurasi dan ketepatan prediksi. Dengan demikian, sistem ini tidak hanya bersifat reaktif, tetapi juga proaktif dan adaptif terhadap dinamika operasional hotel (Sari, 2021; Pratama, Sari and Yuliani, 2024).

Meskipun hasil penelitian ini menjanjikan, penguatan metodologi tetap diperlukan, terutama melalui perluasan jenis data, integrasi otomatisasi, dan uji coba pada kondisi operasional nyata. Pengembangan sistem dengan cakupan data yang lebih luas dan validasi real-time akan meningkatkan keandalan model dalam skala industri yang lebih kompleks dan dinamis..

3.6. Ucapan Terima Kasih

Peneliti mengucapkan terima kasih kepada LPPMI ITNY (Institut Teknologi Nasional Yogyakarta) atas dukungan dan bantuan dana penelitian melalui Program Penelitian ITNY Tahun Anggaran 2025 yang telah memungkinkan terlaksananya penelitian ini.

4. PENUTUP

4.1. Kesimpulan

Berdasarkan hasil yang diperoleh, model ANN menunjukkan performa klasifikasi yang sangat baik terhadap lima kategori kelayakan pemeliharaan hotel. Model berhasil memprediksi 9 data kelas Sangat Tidak Layak (STL) dengan akurasi penuh, 11 data kelas Tidak Layak (TL) secara tepat dengan hanya 2 kesalahan klasifikasi ke STL, serta 15 data kelas Cukup Layak (CL) dengan 1 kesalahan minor ke kelas Layak (L). Kelas Layak (L) diprediksi dengan akurasi tinggi sebanyak 9 data, dan kelas Sangat Layak (SL) berhasil diklasifikasikan secara sempurna tanpa kesalahan.

Temuan ini menegaskan bahwa ANN memiliki kemampuan untuk mengenali pola kompleks dalam data pemeliharaan hotel dan memberikan prediksi yang reliabel. Arsitektur jaringan, proses normalisasi, serta pemilihan parameter pelatihan terbukti efektif dalam

menghasilkan model yang stabil dan dapat diandalkan. Keberhasilan ini mendukung penerapan ANN sebagai solusi strategis dalam sistem pemeliharaan prediktif, khususnya di sektor layanan seperti perhotelan yang menuntut keandalan operasional tinggi.

4.2. Saran

Model ANN yang dikembangkan berpotensi diintegrasikan ke dalam sistem manajemen fasilitas hotel untuk mendukung pengambilan keputusan yang proaktif. Pengembangan lanjutan disarankan melalui dashboard interaktif dan integrasi IoT guna meningkatkan akurasi prediksi secara real-time. Penelitian selanjutnya perlu mencakup dataset yang lebih besar dan data real-time untuk mengatasi keterbatasan ketidakseimbangan kategori dan ketergantungan input manual, sehingga mampu meningkatkan efisiensi, menghemat biaya, dan memperkuat kualitas layanan hotel...

5. DAFTAR PUSTAKA

Abdulhameed, O. *et al.* (2024) 'Development of a Predictive Maintenance System Using Machine Learning Technique', in *Proceedings of the International Conference on Industrial Engineering and Operations Management*. Michigan, USA: IEOM Society International. Available at: <https://doi.org/10.46254/AN14.20240021>.

Contreras, E., Torres-Treviño, L. and Torres, F. (2018) 'Prediction of Car Accidents Using a Maximum Sensitivity Neural Network', in, pp. 86–95. Available at: https://doi.org/10.1007/978-3-319-73323-4_9.

Dharmali, M.J., Lioner, T. and Susilo, V.V. (2021) 'SISTEM KLASIFIKASI KERAPIHAN KAMAR HOTEL MENGGUNAKAN CONVOLUTED NEURAL NETWORK (CNN)', *Computatio : Journal of Computer Science and Information Systems*, 5(2), p. 61. Available at: <https://doi.org/10.24912/computatio.v5i2.15175>.

Krenek, J. *et al.* (2016) 'Application of Artificial Neural Networks in Condition Based Predictive Maintenance', in, pp. 75–86.

Available at: https://doi.org/10.1007/978-3-319-31277-4_7.

Madhukar Dharavath (2024) ‘AI-Driven Predictive Maintenance in Data Infrastructure: A Multi-Modal Framework for Enhanced System Reliability’, International Journal of Scientific Research in Computer Science, Engineering and Information Technology, 10(6), pp. 824–834. Available at: <https://doi.org/10.32628/CSEIT241061118>.

Musril, H.A. et al. (2023) ‘Using k-NN Artificial Intelligence for Predictive Maintenance in Facility Management’, International Journal of Electrical and Electronics Engineering, 10(6), pp. 1–8. Available at: <https://doi.org/10.14445/23488379/IJEEE-V10I6P101>.

Nasser, A. and AL-Khazraji, H. (2022) ‘A hybrid of convolutional neural network and long short-term memory network approach to predictive maintenance’, International Journal of Electrical and Computer Engineering (IJECE), 12(1), p. 721. Available at: <https://doi.org/10.11591/ijece.v12i1.pp721-730>.

Pratama, B.G., Sari, S.N. and Yuliani, O. (2024) ‘Pendekatan Principal Component Analysis untuk Peningkatan Efektivitas Pemeliharaan Jalan Kabupaten’, in ReTII, pp. 164–171.

Reddy Voddi, V.K. (2023) ‘The Role of Neural Networks in Improving Predictive Maintenance Across Industries’, International Journal on Recent and Innovation Trends in Computing and Communication, 11(4), pp. 533–538. Available at: <https://doi.org/10.17762/ijritcc.v11i4.11226>.

Sari, S.N. (2021) ‘Asumsi Prioritas Penanganan pemeliharaan Jalan Kabupaten Menggunakan Metode Analisis Hirarki Proses (AHP)’, in Prosiding CEEDRiMS 2021 Inovasi Teknologi dan Material Terbarukan Menuju Infrastruktur ISBN: 978-602-361-385-4 Yang Aman Terhadap Bencana dan Ramah Lingkungan. Yogyakarta.

Sari, S.N. et al. (2024) ‘Penilaian Pelaksanaan Pemeliharaan dan Perawatan Bangunan Hotel di Sleman Yogyakarta’, G-Tech: Jurnal Teknologi Terapan, 8(3), pp. 1769–1778. Available at: <https://doi.org/10.33379/gtech.v8i3.4556>.

Sari, S.N., Pratama, B.G. and Ircham, I. (2024) ‘Kolaborasi Jaringan Saraf Tiruan (JST) Dalam Identifikasi Prioritas Penanganan Pemeliharaan Jalan Kabupaten’, Device, 14(1), pp. 19–29. Available at: <https://doi.org/10.32699/device.v14i1.6702>.

Sari, S.N., Pratama, B.G. and Prastowo, R. (2024) ‘Pemodelan Artificial Neural Network (ANN) Untuk Identifikasi Bangunan Daerah Rawan Longsor’, Device, 14(1), pp. 8–18. Available at: <https://doi.org/10.32699/device.v14i1.6701>.

Sari, S.N. and Triwuryanto (2021) ‘Kajian Pemeliharaan dan Perawatan Bangunan Gedung Sesuai Dengan Peraturan Menteri Pekerjaan Umum No. 24/Prt/M/2008’, in In Civil Engineering, Environmental, Disaster & Risk Management Symposium (CEEDRiMS) Proceeding.

Tanyıldız, H., Batur Şahin, C. and Batur Dinler, Ö. (2024) ‘Disrupting Downtime: Different Deep Learning Journeys into Predictive Maintenance Anomaly Detection’, NATURENGS MTU Journal of Engineering and Natural Sciences Malatya Turgut Ozal University [Preprint]. Available at: <https://doi.org/10.46572/naturengs.1490748>.

Wang, L., Zhu, Z. and Zhao, X. (2024) ‘Dynamic predictive maintenance strategy for system remaining useful life prediction via deep learning ensemble method’, Reliability Engineering & System Safety, 245, p. 110012. Available at: <https://doi.org/10.1016/j.ress.2024.110012>.

Wang, Y. and Chen, J. (2024) ‘Hotel Energy Management Optimization System Based on Artificial Intelligence’, in 2024 3rd International Conference on Artificial Intelligence and Autonomous Robot Systems (AIARS). IEEE, pp. 667–672. Available at: <https://doi.org/10.1109/AIARS63200.2024.00127>.