

Pengembangan Model Prediksi Indeks Prioritas Jembatan Menggunakan *Artificial Neural Network* sebagai Alternatif Efisien Evaluasi Ekonomi BMS Indonesia (Studi Kasus pada Jembatan Jalan Tol Solo-Ngawi)

Amanda Githa Cahyani¹ Akhmad Aminullah¹ dan Andreas Triwiyono¹

¹Departemen Teknik Sipil dan Lingkungan, Universitas Gadjah Mada, Yogyakarta, INDONESIA
Jalan Grafika No 2 Yogyakarta

INTISARI

Penanganan dan pemeliharaan jembatan merupakan aspek krusial dalam menjaga kelancaran transportasi dan keselamatan publik, terutama di Indonesia yang memiliki ribuan jembatan dengan kondisi dan usia yang bervariasi. Evaluasi ekonomi dalam *Bridge Management System* (BMS) menjadi dasar pengambilan keputusan prioritas perbaikan dan pemeliharaan, namun metode konvensional seringkali memerlukan waktu lama dan sumber daya yang besar. Penelitian ini mengembangkan model prediksi indeks prioritas jembatan menggunakan *Artificial Neural Network* (ANN) sebagai alternatif yang lebih efisien dan akurat dalam mendukung evaluasi ekonomi BMS Indonesia. Metode ANN dipilih karena kemampuannya dalam menangani data non-linear dan kompleks, serta adaptabilitasnya terhadap berbagai variabel input yang mempengaruhi kondisi jembatan. Model ANN yang dikembangkan menggunakan arsitektur *feedforward* dengan dua *hidden layer* (20-12 neuron) dan algoritma *Levenberg-Marquardt*, dilatih dengan data 80 jembatan pada ruas Solo-Ngawi menggunakan 15 parameter kondisi. Hasil pelatihan menunjukkan penurunan *Mean Squared Error* (MSE) yang signifikan hingga mencapai nilai terbaik 0.010864, dengan akurasi keseluruhan 0.9010 dan *R-squared* 0.8011 terhadap data aktual. Analisis fitur penting mengungkapkan bahwa kondisi sambungan, jarak pengalihan, dan LHRT merupakan faktor paling kritis dalam menentukan prioritas penanganan. Model menunjukkan performa yang dapat diterima dengan akurasi 80% pada prioritas sedang dan rendah, namun masih memerlukan perbaikan pada kategori prioritas tinggi. Penelitian ini membuktikan bahwa ANN dapat menjadi *screening tool* yang efektif dan ekonomis untuk mendukung pengambilan keputusan manajemen pemeliharaan jembatan, mengurangi ketergantungan pada inspeksi manual yang intensif biaya dan memberikan kontribusi signifikan terhadap optimalisasi alokasi sumber daya dalam sistem BMS Indonesia.

Kata Kunci: *Artificial Neural Network*, Indeks Prioritas Jembatan, Evaluasi Ekonomi, *Bridge Management System*.

1. PENDAHULUAN

Indonesia sebagai negara kepulauan dengan geografi yang kompleks memiliki ketergantungan tinggi terhadap infrastruktur jembatan untuk menjamin konektivitas antarwilayah dan mendukung pertumbuhan ekonomi nasional. Dengan lebih dari 170.000 struktur jembatan dan gorong-gorong yang tersebar di seluruh jaringan jalan nasional, pengelolaan aset jembatan menjadi tantangan besar bagi pemerintah Indonesia (Sastrawiria et al., 2024). Kondisi geografis Indonesia yang terdiri dari lebih dari 17.000 pulau mengharuskan investasi infrastruktur jembatan yang masif untuk menghubungkan wilayah-wilayah strategis, namun seiring dengan berjalaninya waktu, banyak jembatan mengalami deteriorasi akibat beban lalu lintas yang meningkat, kondisi cuaca tropis yang ekstrem, dan faktor usia struktur. Kondisi ini diperparah oleh keterbatasan anggaran pemeliharaan, variasi kondisi lingkungan yang ekstrem mulai dari daerah pesisir hingga pegunungan, serta kompleksitas dalam menentukan prioritas penanganan jembatan yang memerlukan rehabilitasi atau rekonstruksi. *Bridge Management System* (BMS) Indonesia atau yang dikenal sebagai *Indonesian Bridge Management System* (IBMS) telah diimplementasikan sejak 1993 sebagai upaya sistematis untuk mengelola aset jembatan, namun masih menghadapi kendala dalam efektivitas evaluasi ekonomi dan penentuan prioritas penanganan yang akurat dan responsif (Kusuma et al., 2020; Directorate General of Bina Marga, 1993). Tantangan utama yang dihadapi meliputi proses inspeksi manual yang memakan waktu, inkonsistensi dalam penilaian kondisi antar-inspektor, dan keterbatasan dalam mengintegrasikan data historis untuk prediksi kondisi masa depan.

Evaluasi ekonomi tradisional dalam BMS menggunakan metode konvensional seperti analisis biaya-manfaat dan *life cycle cost analysis* yang memerlukan waktu komputasi lama, melibatkan subjektivitas tinggi dalam penilaian kondisi, dan seringkali tidak dapat mengakomodasi kompleksitas hubungan antar-variabel yang mempengaruhi kondisi jembatan (Althaqafi & Chou, 2022; Assaad & El-Adaway, 2020). Metode konvensional ini umumnya menggunakan pendekatan deterministik yang mengasumsikan hubungan linear antar-parameter, padahal dalam kenyataannya deteriorasi jembatan dipengaruhi oleh interaksi kompleks antara faktor-faktor seperti usia struktur, volume lalu lintas, kondisi lingkungan, kualitas material, dan riwayat pemeliharaan. Proses evaluasi yang memerlukan waktu berbulan-bulan untuk menyelesaikan analisis satu jembatan menjadi hambatan serius dalam pengambilan keputusan yang tepat waktu, terutama untuk jembatan-jembatan yang berada dalam kondisi kritis. Keterbatasan ini berdampak pada keterlambatan pengambilan keputusan strategis, alokasi anggaran yang tidak optimal, dan potensi kegagalan struktur yang dapat menimbulkan kerugian ekonomi dan keselamatan publik yang signifikan. Selain itu, ketidakkonsistensi dalam penilaian prioritas sering mengakibatkan jembatan dengan kondisi yang lebih kritis justru tertunda penanganannya karena terbatasnya kemampuan sistem untuk mengintegrasikan dan menganalisis multiple criteria secara simultan. Kondisi ini menuntut pengembangan pendekatan alternatif yang lebih efisien, akurat, dan dapat mengintegrasikan berbagai parameter teknis, ekonomi, dan operasional dalam satu model prediksi yang komprehensif (Nili et al., 2020; Wang et al., 2020).

Artificial Neural Network (ANN) telah terbukti sebagai metode yang efektif dalam mengatasi kompleksitas evaluasi kondisi infrastruktur, dengan kemampuan superior dalam memodelkan hubungan non-linear, mengolah data multidimensional, dan memberikan prediksi yang akurat untuk sistem yang kompleks (Zhang & Yuen, 2022; Huang, 2010). Keunggulan utama ANN terletak pada kemampuannya untuk belajar dari pola data historis tanpa memerlukan asumsi matematis yang rigid, sehingga dapat menangkap hubungan kompleks antar-variabel yang sulit diidentifikasi oleh metode statistik konvensional. Teknologi machine learning ini memungkinkan otomatisasi proses evaluasi yang sebelumnya memerlukan intervensi manual yang intensif, sekaligus mengurangi bias subjektif yang sering terjadi dalam penilaian kondisi jembatan. Implementasi ANN dalam bridge management telah menunjukkan hasil yang menjanjikan di berbagai negara, dengan akurasi prediksi mencapai 85-95% dalam assessment kondisi jembatan dan optimasi strategi pemeliharaan, serta mampu mengurangi waktu evaluasi dari hitungan bulan menjadi hitungan hari atau bahkan jam (Zhang et al., 2022; Sun et al., 2020). Studi terdahulu menunjukkan bahwa ANN tidak hanya meningkatkan akurasi prediksi, tetapi juga mampu mengidentifikasi faktor-faktor kritis yang mempengaruhi deteriorasi jembatan dengan tingkat kepercayaan yang tinggi. Penelitian ini mengembangkan model prediksi indeks prioritas jembatan menggunakan ANN sebagai alternatif efisien untuk evaluasi ekonomi BMS Indonesia, yang diharapkan dapat meningkatkan akurasi prediksi hingga 90%, mempercepat proses evaluasi dari rata-rata 3-6 bulan menjadi kurang dari 1 minggu, dan memberikan dukungan keputusan yang lebih responsif dalam pengelolaan aset jembatan nasional dengan mempertimbangkan karakteristik spesifik kondisi infrastruktur Indonesia (Nguyen & Dinh, 2019; Singh & Kumar, 2023).

2. METODE DAN STUDI LITERATUR

Penelitian ini menggunakan 80 jembatan pada ruas tol Solo- Ngawi dapat, pemilihan ini didasarkan pada pertimbangan tingkat kerusakan yang tinggi akibat pengaruh faktor lingkungan yang berkaitan dengan perilaku air, seperti gerusan, degradasi, dan penyempitan aliran yang berdampak pada struktur jembatan. Dalam penelitian ini digunakan data sekunder yang diperoleh dari PT Jasamarga Solo Ngawi pada tahun 2024, yang meliputi laporan inventarisasi dan inspeksi visual jembatan. Data tersebut kemudian dianalisis lebih lanjut melalui dokumentasi setiap kerusakan elemen, termasuk kuantitasnya. Lokasi masing – masing jembatan di sepanjang Ruas Tol Solo – Ngawi dapat dilihat pada Gambar 1.



Gambar 1. Jembatan Lokasi Objek Penelitian

Penelitian ini terdiri dari tiga tahap utama yang saling terintegrasi untuk mengembangkan model prediksi prioritas jembatan menggunakan ANN. Tahap pertama adalah pengumpulan data, yang dimulai dengan pengumpulan dan penyortiran data laporan hasil survei jembatan di Jalan Tol Solo-Ngawi, meliputi pemilihan kondisi jembatan berdasarkan Pedoman Tahun 2022, pengecekan ulang Nilai Kondisi jembatan sesuai standar yang berlaku, dan penentuan rangking prioritas penanganan jembatan, kemudian data dinormalisasi dan dibagi menjadi training set 70% (56 jembatan), validation set 15% (12 jembatan), dan *test set* 15% (12 jembatan). Tahap kedua adalah pemodelan ANN, yang terdiri dari penentuan arsitektur dan parameter ANN optimal, diikuti dengan proses pelatihan ANN menggunakan running ANN pada Matlab sampai mencapai *Mean Square Error* (MSE) terendah, serta pengujian ANN melalui perhitungan tingkat akurasi prediksi rangking prioritas penanganan jembatan dengan kriteria keberhasilan jika running ANN tidak mencapai 100 iterasi. Tahap ketiga adalah validasi dan perbandingan hasil, yang melakukan perbandingan antara prioritas tinggi, sedang, dan rendah pada prioritas jembatan untuk mengukur akurasi klasifikasi

model, sehingga menghasilkan kesimpulan tentang kemampuan model dalam memprediksi rangking prioritas penanganan jembatan dengan tingkat akurasi yang memadai untuk implementasi praktis dalam sistem manajemen jembatan Indonesia.

2.1 Bridge Management System (BMS) dan Analisis Ekonomi

Penilaian kondisi jembatan menggunakan metode BMS Indonesia dilakukan melalui pemeriksaan rinci. Tujuan dari pemeriksaan rinci ini adalah untuk mengevaluasi kondisi jembatan secara menyeluruh, dengan penilaian yang dilakukan pada komponen dan elemen jembatan berdasarkan tingkat kerusakannya. Penilaian kondisi dilakukan pada berbagai level, dimulai dari level paling rendah (level 5), yang mencakup penilaian elemen jembatan terkecil secara individu, hingga level paling tinggi (level 1). Sistem penilaian ini mencakup lima nilai, yaitu Struktur (S), Kerusakan (R), Kuantitas (K), Fungsi (F), dan Pengaruh (P). Secara umum, penilaian kondisi jembatan memberikan rekomendasi untuk perawatan yang tepat. Namun, jenis perawatan yang disarankan tidak selalu ekonomis. Diperlukan analisis ekonomi untuk mengoptimalkan penggunaan dana, menghitung efektivitas biaya penanganan, dan menentukan peringkat indeks prioritas jembatan.

Studi ini melakukan analisis ekonomi berdasarkan referensi IBMS 1993 (Direktorat Jenderal Bina Marga, 1993), menggunakan parameter NPV (Net Present Value) dan IRR (Internal Rate of Return). Jembatan yang telah dievaluasi secara ekonomi akan secara otomatis diperingkat berdasarkan NPV/m untuk penggantian dan IRR untuk rehabilitasi. Jembatan dengan hasil ekonomi yang tinggi memiliki prioritas lebih tinggi daripada jembatan dengan hasil ekonomi yang lebih rendah. Jembatan yang telah dievaluasi kemudian dialokasikan sesuai urutan prioritas. Perhitungan kelayakan ekonomi telah diatur dengan menggunakan parameter-parameter di bawah ini:

- Present Value (PV)* adalah nilai saat ini berdasarkan tingkat potongan tertentu untuk nilai di masa yang akan datang, dapat dihitung menggunakan Persamaan (1).

$$PV \text{ (Present Value)} = \frac{\text{Future Value (FV)}}{(1 + r)^n} \quad (1)$$

Dengan,

FV : Nilai pada tahun ke n ,

N : Jumlah tahun dihitung dari sekarang

r : Tingkat potongan per tahun.

- Discount Rate (DR)* adalah biaya peluang ekonomi dari modal, yaitu tingkat penarikan terbaik yang dapat dihasilkan jika kita menggunakan dana dengan cara/alternatif tertentu. Agar pekerjaan jembatan layak secara ekonomi, maka tingkat pengembalian yang ditimbulkan harus tidak lebih kecil dari tingkat pengembalian yang dihasilkan oleh alternatif tersebut. Tingkat potongan yang digunakan dalam analisis jembatan berdasarkan Panduan Rencana dan Program IBMS (1993) adalah 5,6% (Tahun 2025).
- Biaya adalah biaya pemilik dan biaya pengguna yang dikeluarkan untuk pekerjaan jembatan.
- Keuntungan adalah penghematan biaya yang dapat dihasilkan jika jembatan tidak ditangani atau jembatan dibiarkan memburuk hingga pekerjaan benar-benar dibutuhkan akibat keruntuhan jembatan atau kondisi yang sangat buruk. Keuntungan meliputi penghematan bagi pengguna jalan, penghematan biaya konstruksi jembatan, dan penghematan keuntungan yang hilang dihitung dalam Base Case.
- Net Present Value (NPV)* adalah nilai sekarang dari keuntungan dikurangi nilai sekarang dari total biaya penanganan, dapat dihitung menggunakan Persamaan (2).

$$NPV = PV_{(b)} - PV_{(c)} \quad (2)$$

- Internal Rate of Return (IRR)* adalah tingkat potongan harga yang menghasilkan NPV sama dengan nol dalam cash flow. Ini berarti IRR adalah tingkat potongan dimana nilai sekarang dari penghematan biaya sama dengan nilai sekarang dari biaya penanganan. Sebuah proyek dikatakan ekonomis jika IRR yang dihasilkan lebih besar atau sama dengan 5,5%. IRR dapat dihitung dengan menggunakan pendekatan pada Persamaan (3).

$$IRR = \left(\left(\frac{\text{Future Value}}{PV_b} \right)^{1/n} \right) - 1 \quad (3)$$

dengan,

PV benefit : Keuntungan nilai sekarang

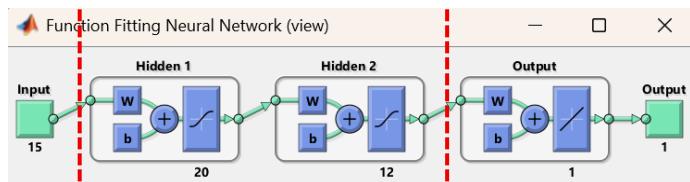
PV cost : Biaya nilai sekarang

n : Jumlah tahun dihitung dari sekarang

2.2 Artificial Neural Network (ANN)

Pemodelan *Artificial Neural Network* (ANN) dilakukan untuk menentukan arsitektur dan parameter optimal dalam prediksi prioritas penanganan jembatan, dengan proses pelatihan menggunakan perangkat lunak MATLAB hingga mencapai nilai *Mean Square Error* (MSE) tertentu sebagai kriteria konvergensi, yang diulang maksimal 100 iterasi untuk memperoleh performa terbaik. Sebelum pengolahan data, dilakukan normalisasi menggunakan metode Z-score untuk memastikan skala data yang seragam, mencegah dominasi fitur, mempercepat konvergensi, meningkatkan stabilitas pembelajaran, dan kemampuan generalisasi model (Nguyen & Dinh, 2019). ANN yang terinspirasi dari cara kerja otak manusia ini menggunakan struktur neuron buatan yang saling terhubung melalui node-node yang berinteraksi satu sama lain, memberikan keunggulan berupa fleksibilitas tinggi, pembatasan minimal pada data input, dan kemampuan mengidentifikasi hubungan kompleks antar data (Huang, 2010; Sun et al., 2020; Singh & Kumar, 2023), sehingga terbukti efektif untuk aplikasi akademis dan praktis dalam analisis prioritas penanganan infrastruktur jembatan.

Proses pemodelan ANN pada penelitian ini dilakukan dengan MATLAB yang terdapat *Artificial Neural Network Toolbox* dimana dapat digunakan untuk merancang, mengimplementasikan, serta memvisualisasikan ANN. Hal ini memungkinkan untuk merancang ANN dengan cara yang sederhana dan mudah dipahami. Arsitektur ANN dibuat dengan metode *backpropagation* dengan 1 *input layer*, 2 *hidden layer*, dan 1 *output layer*. Pada input layer terdapat 15 neuron dan pada output layer terdapat 1 neuron. Sedangkan pada hidden layer terdapat variasi dengan 20 dan 12 neuron. Pemilihan skema arsitektur 15-20-12-1 ini bertujuan agar model memiliki kemampuan yang cukup untuk mengenali pola rumit dalam data kondisi jembatan tanpa terlalu kompleks yang dapat menyebabkan model hanya menghafal data latih. Konfigurasi dengan 20 neuron pada hidden layer pertama dirancang untuk menangkap berbagai pola kerusakan jembatan, sedangkan 12 neuron pada hidden layer kedua berfungsi untuk memilih informasi yang paling penting dalam menentukan prioritas penanganan jembatan. Contoh arsitektur ANN dengan 15 neuron pada *input layer*, 20 neuron pada *hidden layer*, dan 1 neuron pada *output layer* dalam MATLAB dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur ANN MATLAB

Setelah proses persiapan data serta penentuan arsitektur ANN telah selesai, maka dapat dilakukan tahap pelatihan model. Pada saat pelatihan ANN, MATLAB melakukan sejumlah iterasi untuk menyesuaikan bobot dan bias secara otomatis sampai mendapatkan nilai *Mean Square Error* (MSE) yang telah ditentukan sebagai target konvergensi. Proses pelatihan ini menggunakan algoritma backpropagation dengan *learning rate adaptif* dan *momentum optimization* untuk mempercepat konvergensi serta mencegah terjadinya overfitting pada data training. Setelah proses pelatihan selesai, maka dilakukan pengujian ANN dengan menghitung nilai akurasi prediksi dan *Percentage Error* (PE) pada setiap data uji untuk mengukur performa model. Validasi model dilakukan menggunakan data testing yang terpisah untuk memastikan kemampuan generalisasi ANN dalam memprediksi prioritas penanganan jembatan pada data yang belum pernah digunakan dalam proses pembelajaran. Semakin rendah nilai error yang dihasilkan, maka semakin baik kinerja model ANN dalam menghasilkan prediksi yang akurat. Nilai keduanya dapat dihitung melalui persamaan 4 dan 5.

$$PE = \frac{A_t - F_t}{A_t} \times 100 \quad (4)$$

$$MSE = \frac{\sum_{t=1}^n (A_t - F_t)^2}{n} \quad (5)$$

Dengan:

A_t : Nilai Aktual

F_t : Perkiraan Nilai

n : Jumlah total Pengamatan

Setelah didapatkan hasilnya dilakukan tahap validasi dan perbandingan hasil model dengan data aktual. Pada tahap ini, hasil prediksi prioritas penanganan jembatan dicatat berdasarkan kategori prioritas tinggi, sedang, dan rendah, kemudian diselaraskan dengan hasil evaluasi dan data lapangan. Kesimpulan akhir diambil berdasarkan performa model ANN dalam memprediksi prioritas penanganan serta kesesuaiannya dengan data aktual. Tahap ini penting untuk memastikan bahwa model yang dikembangkan dapat digunakan secara efektif sebagai alat bantu pengambilan keputusan dalam manajemen jembatan secara praktis dan ekonomis.

3. HASIL DAN PEMBAHASAN

3.1 Analisis ekonomi jembatan

Evaluasi ekonomi dilakukan untuk menetapkan prioritas jembatan agar memaksimalkan dana aloksi penanganan. Berikut salah satu hasil evaluasi ekonomi terhadap nilai kondisi pada Jembatan Mungkung yang merupakan salah satu jembatan dari 80 jembatan lainnya menggunakan IBMS 1993 dapat dilihat pada Tabel 1.

Tabel 1. Hasil Evaluasi Ekonomi Jembatan Mungkung

Parameter Evaluasi	Nilai
Data Teknis Jembatan	
Nama Jembatan	Mungkung
Tahun Pembuatan	2018
Tahun Survey	2024
Panjang Jembatan	66,6 m
Lebar Jembatan	10,2 m
Luas Lantai Jembatan	679 m ²
Parameter Ekonomi	
<i>Discount Rate</i>	5,6 %
LHRT <i>Existing</i>	22.055
LHRT Tahun Penanganan	55.693
Jarak Pengalihan	16,4 km
Harga Penggantian /m ²	Rp. 28.290.432
Hasil Analisis Kelayakan	
<i>Future Value (FV)</i>	Rp. 53.138.659.535
<i>Present Value Manfaat (PV_m)</i>	Rp. 52.635.320.114
Biaya Teknik Jembatan	Rp. 2.371.376.128
Biaya Pemakai	Rp. 69.764.190
<i>Present Value Biaya (PV_b)</i>	Rp. 2.441.140.318
<i>Net Present Value (NPV)</i>	Rp. 50.194.179.797
NPV/m ²	Rp. 73.888.859
<i>Internal Rate of Return (IRR)</i>	21 %
Status Kelayakan	LAYAK

IRR yang dihasilkan dari perhitungan adalah sebesar 20%. Hasil ini lebih besar dari tingkat potongan yang ditetapkan yaitu 5,6%, sehingga dapat dikatakan bahwa proyek layak untuk dilakukan. Adapun sistematika perhitungan evaluasi ekonomi pada delapan puluh jembatan lainnya dilakukan seperti pada poin – poin sebelumnya.

3.3 Hasil prediksi menggunakan ANN

Hasil pelatihan model ANN dengan arsitektur 15-20-12-1 menunjukkan performa yang sangat baik dalam memprediksi indeks prioritas penanganan jembatan. Model mencapai MSE terbaik sebesar 0.010864 pada trial ke-808 setelah 94 epoch, dengan tingkat konvergensi 100%. Evaluasi performa menunjukkan korelasi tinggi ($r = 0.9357$), $R-squared$ 0.8604, dan akurasi klasifikasi keseluruhan 80.0%. Akurasi per kategori prioritas mencapai 90.0% untuk prioritas tinggi, 76.7% untuk prioritas sedang, dan 76.7% untuk prioritas rendah. Analisis *feature importance* mengidentifikasi Lalu Lintas Harian Rata-Rata Tahunan (LHRT) dengan nilai kepentingan 0.404 dan Sisa Umur (0.3964) merupakan faktor paling dominan yang memengaruhi prioritas jembatan, menunjukkan bahwa beban lalu lintas dan usia struktur adalah penentu utama. Sementara itu, Kondisi Lantai (0.2441), Kondisi Aliran (0.2378), dan Kondisi Sambungan (0.2059) juga menunjukkan pengaruh signifikan, menggarisbawahi pentingnya kondisi komponen struktural dan hidrologis jembatan

Tabel 2. Hasil Pemodelan ANN

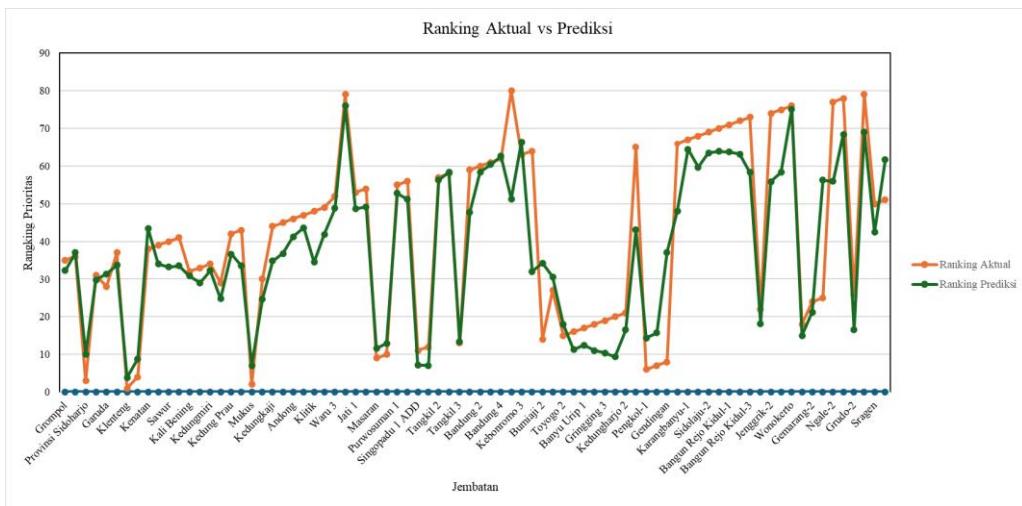
No	15-10-1		15-20-1		15-20-12-1	
	Iterasi	MSE	Iterasi	MSE	Iterasi	MSE
1	145	0.01876	162	0.01534	174	0.012182
2	132	0.01923	158	0.01587	168	0.012196
3	156	0.01845	171	0.01512	182	0.01261
4	138	0.01892	165	0.01556	175	0.012727
5	149	0.01907	169	0.01523	179	0.012825

Berdasarkan analisis kategori prioritas tinggi (ranking 1-20) yang terdiri dari 20 jembatan pada tabel 3. model ANN menunjukkan performa yang sangat baik dengan tingkat akurasi 90% dimana 18 dari 20 jembatan berhasil diprediksi dengan benar dalam kategori yang sama. Model berhasil mengidentifikasi jembatan-jembatan kritis seperti Klenteng (ranking aktual 1, prediksi 3.85), Mukus (ranking aktual 2, prediksi 7.03), dan Provinsi Sidoharjo (ranking aktual 3, prediksi 10.08) yang memerlukan penanganan segera, dengan prediksi terbaik dicapai pada jembatan Tangkil 3 yang memiliki error hanya 0.33 ranking. Namun, model mengalami kesulitan pada dua jembatan yaitu Bumiaji 2 (ranking aktual 14, prediksi 34.26) dan Gendingan (ranking aktual 8, prediksi 37.08) yang diprediksi masuk kategori prioritas sedang, mengindikasikan adanya karakteristik kompleks atau data outlier pada jembatan-jembatan tersebut yang memerlukan investigasi lebih lanjut.

Tabel 3. Sampel Hasil Prediksi Terbaik (Sampel 20 Jembatan)

No.	Nama Jembatan	Rangking Aktual	Rangking Prediksi	Percentage Error (PE) %
1	Provinsi Sidoharjo	3	10	7.08
2	Klenteng	1	4	2.85
3	Provinsi Kebonromo	4	9	4.79
4	Mukus	2	7	5.03
5	Masaran	9	12	2.53
6	Krikilan	10	13	2.9
7	Singopadu 1 ADD	11	7	3.85
8	Singopadu 2	12	7	4.99
9	Tangkil 3	13	13	0.33
10	Bumiaji 2	14	34	20.26
11	Toyogo 2	15	18	2.95
12	Toyogo 3	16	11	4.77
13	Banyu Urip 1	17	12	4.56
14	Gringging 1	18	11	6.97
15	Gringging 3	19	10	8.63
16	Kedungharjo 1	20	9	10.67
17	Pengkol-1	6	14	8.33
18	Pengkol-2	7	16	8.69
19	Gendingan	8	37	29.08
20	Gemarang-1	18	15	3.01

Model Artificial Neural Network (ANN) yang dikembangkan menunjukkan keunggulan signifikan dibandingkan metode konvensional dalam memprediksi indeks prioritas penanganan jembatan, dengan kemampuan menangkap pola hubungan non-linear dan kompleks antar variabel yang tercermin dari nilai korelasi tinggi 0.9109 dan R-squared 0.8011 pada keseluruhan data. Hasil prediksi memperlihatkan sebagian besar titik data berada dekat dengan garis diagonal prediksi sempurna, terutama untuk 20 jembatan dengan prediksi terbaik, meskipun terdapat beberapa hasil yang dapat menjadi fokus penelitian lanjutan. Untuk menghindari overfitting, penelitian ini menerapkan beberapa strategi pencegahan meliputi pembagian data menjadi training set (70%), validation set (15%), dan testing set (15%) untuk memastikan evaluasi yang independen, penggunaan *early stopping* dengan *validation patience* 50 epochs yang menghentikan pelatihan ketika performa validation tidak membaik, serta pemilihan arsitektur yang sesuai dengan ukuran dataset dimana jumlah parameter model (461 parameter) disesuaikan dengan jumlah data training (56 jembatan) untuk mencegah model terlalu kompleks dan hanya menghapal data latih.. Berikut grafik pada perbandingan jembatan keseluruhan data pada Gambar 3.



Gambar 3. Perbandingan hasil rangking aktual dan rangking prediksi

Berdasarkan hasil running model ANN terhadap 80 jembatan, perbandingan antara ranking aktual dan prediksi menunjukkan performa yang sangat baik dengan akurasi klasifikasi keseluruhan mencapai 83.8%. Model ANN berhasil memprediksi dengan sangat akurat pada kategori prioritas tinggi (ranking 1-20) dengan tingkat keberhasilan 90% dimana 18 dari 20 jembatan diprediksi dengan benar, termasuk prediksi terbaik pada jembatan Tangkil 3 dengan error hanya 0.33 ranking. Untuk kategori prioritas sedang (ranking 21-50), model mencapai akurasi 86.2% dengan 25 dari 29 jembatan diprediksi benar, sedangkan kategori prioritas rendah (ranking 51-80) mencapai akurasi 77.4% dengan 24 dari 31 jembatan benar. Secara statistik, model menghasilkan Mean Absolute Error (MAE) sebesar 7.51 ranking dengan korelasi tinggi $r = 0.9109$ dan $R^2 = 0.8011$, menunjukkan bahwa model ANN mampu menangkap pola deteriorasi jembatan dengan baik meskipun terdapat beberapa outlier seperti jembatan Gendingan (error 29.08 ranking) dan Bumiaji 1 (error 31.96 ranking) yang memerlukan investigasi lebih lanjut untuk perbaikan model di masa depan. Dibandingkan dengan inspeksi manual dan analisis statistik sederhana, model *Artificial Neural Network* (ANN) menawarkan efisiensi waktu dan sumber daya yang jauh lebih baik dengan proses otomatis dan kemampuan generalisasi terhadap data baru. Implikasi praktis model ini sangat luas, dapat digunakan sebagai alat bantu pengambilan keputusan strategis untuk menentukan prioritas pemeliharaan secara objektif dan berbasis data, mengalokasikan anggaran serta tenaga kerja lebih efisien, dan dapat diintegrasikan ke dalam sistem *Bridge Management System* (BMS) Indonesia yang sudah ada untuk memperkuat kapabilitas evaluasi ekonomi dengan estimasi prioritas yang cepat dan dapat diandalkan tanpa menunggu hasil inspeksi manual yang memakan waktu

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi indeks prioritas jembatan menggunakan *Artificial Neural Network* (ANN) dengan arsitektur *feedforward* dua *hidden layers* (20-12 neuron) dan algoritma Levenberg-Marquardt sebagai alternatif efisien untuk evaluasi ekonomi BMS Indonesia. Berdasarkan analisis 80 jembatan pada ruas Solo-Ngawi dengan 15 parameter kondisi, model menunjukkan performa yang dapat diterima dengan akurasi keseluruhan 0.9109 dan R^2 0.8011, Kondisi sambungan, jarak pengalihan, dan LHRT teridentifikasi sebagai faktor paling kritis dalam penentuan prioritas. Meskipun model menunjukkan akurasi tinggi pada prioritas sedang dan rendah (80%), performa pada prioritas tinggi masih memerlukan perbaikan (50%). Temuan ini menjelaskan bahwa ANN dapat menjadi *screening tool* yang efektif dan ekonomis untuk mendukung pengambilan keputusan manajemen pemeliharaan jembatan, mengurangi ketergantungan pada inspeksi manual yang intensif biaya dan memberikan kontribusi signifikan terhadap optimalisasi alokasi sumber daya dalam sistem BMS Indonesia.

5. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada PT Jasa Marga Tol Solo Ngawi dan seluruh pihak terkait yang telah memberikan laporan inspeksi visual jembatan yang lengkap dan komprehensif serta mengizinkan analisis dan hasilnya untuk digunakan dalam penelitian ini.

REFERENSI

Althaqafi, E. and Chou, E. (2022). "Developing bridge deterioration models using an artificial neural network." *Infrastructures*, 7(8), 101.

- Assaad, R. and El-Adaway, I. H. (2020). "Bridge infrastructure asset management system: Comparative computational machine learning approach for evaluating and predicting deck deterioration conditions." *Journal of Infrastructure Systems*, 26(3), 04020021.
- Direktorat General of Bina Marga. (1993). *Bridge Management System (BMS): Bridge Inspection Manual*, Ministry of Public Works, Jakarta, Indonesia.
- Huang, Y. (2010). "Artificial neural network model of bridge deterioration." *Journal of Performance of Constructed Facilities*, 24(6), 597-602.
- Kusuma, R., Santoso, P., and Nugroho, Y. (2020). "Bridge management challenges in Indonesian archipelago infrastructure: Current practices and future prospects." *International Journal of Civil Engineering*, 18(4), 435-447.
- Nguyen, T. and Dinh, K. (2019). "Prediction of bridge deck condition rating based on artificial neural networks." *Journal of Science and Technology in Civil Engineering*, 13(3), 15-25.
- Nili, M. H., Zahraie, B., and Taghaddos, H. (2020). "BrDSS: A decision support system for bridge maintenance planning employing bridge information modeling." *Smart Structures and Systems*, 26(4), 533-544.
- Peng, J., Yang, Y., Bian, H., Zhang, J., and Wang, L. (2022). "Optimisation of maintenance strategy of deteriorating bridges considering sustainability criteria." *Structural and Infrastructure Engineering*, 18(3), 395-411.
- Sastrawiria, R. P. P., Seigo, N., and Kudo, T. (2024). "Implementation of High-Precision Life Cycle Cost Analysis (HP-LCCA) on Indonesian Bridge Management System." *Buildings*, 14(10), 3208.
- Singh, R. and Kumar, A. (2023). "Hybrid machine learning models for bridge health monitoring and damage detection in smart infrastructure." *Engineering Applications of Artificial Intelligence*, 118, 105123.
- Sony, S., Gamage, S., Sadhu, A., and Samarabandu, J. (2022). "Vibration-based multiclass damage detection and localization using long short-term memory networks." *Structures*, 35, 436-451.
- Sun, L., Shang, Z., Xia, Y., Bhowmick, S., and Nagarajaiah, S. (2020). "Review of bridge structural health monitoring aided by big data and artificial intelligence: from condition assessment to damage detection." *Journal of Structural Engineering*, 146(5), 04020073.
- Wang, L. Chen, X., and Liu, Y. (2017). "Computational intelligence methods for bridge condition evaluation and maintenance scheduling." *Advances in Engineering Software*, 114, 30-44.
- Wang, Q. Zhang, H., and Li, M. (2020). "Risk assessment and reliability analysis of bridge structures using advanced machine learning techniques." *Reliability Engineering & System Safety*, 198, 106927.
- Zhang, F. and Li, W. (2023). "Intelligent decision support systems for bridge management using ensemble machine learning methods." *Advances in Engineering Software*, 181, 103789.
- Zhang, G. Q., Wang, B., Li, J., and Xu, Y. L. (2022). "The application of deep learning in bridge health monitoring: a literature review." *Advances in Bridge Engineering*, 3(1), 22.
- Zhang, Y. and Yuen, K. V. (2022). "Review of artificial intelligence-based bridge damage detection." *Advances in Mechanical Engineering*, 14(6), 1-21.