

---

---

## PENERAPAN JARINGAN SYARAF TIRUAN UNTUK PREDIKSI JUMLAH PENUMPANG KERETA API MENGGUNAKAN ALGORITMA BACKPROPAGATION

**Zulfa AR Rahman<sup>1</sup>, Wanayumini<sup>2</sup>**

**Universitas Asahan, Kisaran**

e-mail: <sup>1</sup> zulfaarahman80@gmail.com, <sup>2</sup> wanayumini@yahoo.co.id

**Abstract** : *The number of rail passengers on the Kisaran–Medan route varies over time due to a number of variables, including local economic situations, national holidays, peak travel seasons, and current transportation regulations. The administration of Kisaran Station finds it challenging to manage train fleets, organize travel timetables, and enhance service quality due to this unpredictability. Using historical data from 2019 to 2025, this study intends to apply an Artificial Neural Network (ANN) with the Backpropagation technique to forecast the number of train passengers at Kisaran Station. With a learning rate of 0.25 and a sigmoid binary activation function, the system was constructed using a 7-5-1 network architecture with seven input neurons (yearly data from 2019–2025), five hidden layer neurons, and one output neuron. The data was split into 70% training data (January–July) and 30% testing data (August–December) after being adjusted to the interval 0.1–0.9 using the Min-Max technique. At epoch 822, the training process reached a convergence. For most months, including March (predicted: 647,271; actual: 642,870 passengers) and April (predicted: 999,728; actual: 996,320 passengers), the model was able to produce predictions that were close to actual values, according to testing results. However, there were differences in some months with seasonal spikes. It is anticipated that PT Kereta Api Indonesia and the regional government would use the created prediction system as a decision-support tool to plan transportation services and enhance the general quality of railway services.*

**Keywords:** *Kisaran–Medan Route, Backpropagation, Artificial Neural Network, Train Passenger Prediction, PHP-Based System.*

**Abstrak** : Berbagai faktor, termasuk hari libur nasional, musim mudik, kondisi ekonomi masyarakat, dan kebijakan transportasi yang berlaku, memengaruhi jumlah penumpang kereta api pada rute Kisaran–Medan. Karena ketidakstabilan ini, manajemen Stasiun Kisaran menghadapi kesulitan dalam merencanakan jadwal perjalanan, mengelola armada kereta api, dan meningkatkan pelayanan penumpang. Studi ini menggunakan algoritma backpropagation Jaringan Syaraf Tiruan (JST) untuk memprediksi jumlah penumpang kereta api di Stasiun Kisaran dari tahun 2019 hingga 2025. Arsitektur jaringan 7-5-1 digunakan untuk sistem ini. Ada tujuh neuron input (data tahunan 2019–2025), lima neuron pada lapisan tersembunyi, dan satu neuron output. Rata-rata pembelajarannya adalah 0,25, dan ada fungsi aktivasi sigmoid biner. Data dinormalisasi dengan metode Min-Max ke interval 0,1–0,9. Selanjutnya, 70% data pelatihan (Januari–Juli) dan 30% data pengujian (Agustus–Desember) dibagi. Pada epoch ke-822, pelatihan berhenti. Hasil pengujian menunjukkan bahwa model mampu memproyeksikan nilai yang hampir sama dengan nilai aktual pada sebagian besar bulan. Misalnya, pada bulan Maret, model memproyeksikan 647.271 penumpang, sedangkan nilai sebenarnya adalah 642.870 penumpang, dan pada bulan April, model memproyeksikan 999.728 penumpang, sedangkan nilai sebenarnya adalah 996.320 penumpang. Namun, ada perbedaan pada beberapa bulan karena lonjakan musiman. Diharapkan sistem prediksi ini akan membantu PT Kereta Api Indonesia dan pemerintah daerah membuat keputusan tentang perencanaan layanan serta meningkatkan kualitas transportasi kereta api.

**Kata kunci:** Jaringan Syaraf Tiruan, Backpropagation, Prediksi Penumpang Kereta Api, Rute Kisaran-Medan, dan Sistem Berbasis PHP

## PENDAHULUAN

Jaringan Syaraf Tiruan (JST) adalah model komputasi yang terinspirasi oleh struktur dan fungsi jaringan saraf biologis pada otak manusia. JST terdiri dari sejumlah unit pemroses sederhana (neuron) yang terhubung satu sama lain melalui bobot sinaptik (Nico Nico & Pipin Farida Ariyani, 2025). Dalam konteks prediksi jumlah penumpang kereta api, penerapan JST dengan Backpropagation diharapkan mampu memberikan hasil prediksi yang lebih optimal dibandingkan metode konvensional, serta dapat membantu pihak terkait dalam perencanaan dan pengambilan keputusan di bidang transportasi.

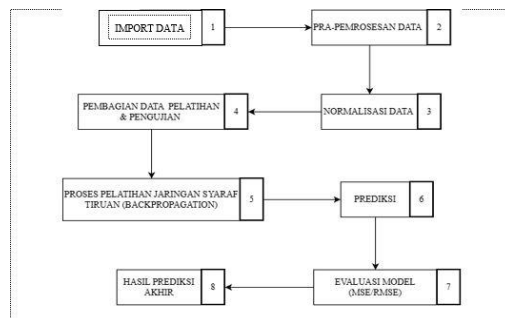
Stasiun Kisaran yang berada di Kabupaten Asahan, Provinsi Sumatera Utara merupakan salah satu titik penting dalam pelayanan transportasi kereta api, khususnya dalam mendukung mobilitas masyarakat di wilayah Kisaran dan sekitarnya. Jumlah penumpang kereta api di Stasiun Kisaran cenderung mengalami fluktuasi dari waktu ke waktu yang dipengaruhi oleh berbagai faktor seperti hari libur, musim mudik, kondisi ekonomi masyarakat, dan kebijakan transportasi yang berlaku. Fluktuasi ini menjadi tantangan bagi pihak manajemen dalam merencanakan jadwal perjalanan, pengelolaan armada, serta peningkatan kualitas pelayanan kepada penumpang.

Penelitian terdahulu oleh Ajik Malik Saputra (2026) menerapkan algoritma Backpropagation pada JST untuk memprediksi jumlah penduduk Provinsi Nusa Tenggara Barat dengan tiga arsitektur jaringan (4-15-1, 4-10-1, dan 4-5-1). Hasil terbaik diperoleh pada arsitektur 4-15-1 dengan MAPE sebesar 2,78%, menunjukkan JST mampu menangkap pola pertumbuhan penduduk secara akurat. Penelitian lain oleh Yusuf & Hani Dewi Ariessanti (2025)

menerapkan Backpropagation untuk prediksi penjualan pakaian jadi di industri garmen dengan hasil akurasi 92,5% dan nilai MSE yang rendah. Berdasarkan kajian tersebut, penelitian ini mengembangkan model prediksi jumlah penumpang kereta api rute Kisaran–Medan menggunakan JST Backpropagation berbasis sistem PHP dan MySQL.

## METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional. Data yang digunakan adalah data historis jumlah penumpang kereta api rute Kisaran–Medan dari tahun 2019 hingga 2025 yang bersumber dari PT Kereta Api Indonesia (Persero), terdiri dari 84 data bulanan (7 tahun  $\times$  12 bulan). Tahapan penelitian meliputi pengumpulan data, normalisasi, perancangan model JST, pelatihan dengan Backpropagation, dan pengujian sistem.



**Gambar 1 Kerangka Kerja**

Variabel input yang digunakan terdiri dari data penumpang tujuh tahun berturut-turut ( $X_1=2019$ ,  $X_2=2020$ ,  $X_3=2021$ ,  $X_4=2022$ ,  $X_5=2023$ ,  $X_6=2024$ ,  $X_7=2025$ ), sedangkan target output adalah data prediksi tahun 2026. Arsitektur JST yang dirancang adalah 7-5-1, yaitu 7 neuron input, 5 neuron hidden layer dengan fungsi aktivasi Sigmoid Biner, dan 1 neuron output dengan fungsi

aktivasi Identitas. Parameter pelatihan ditetapkan sebagai berikut: learning rate ( $\alpha$ ) = 0,25; maksimum epoch = 1000; dan normalisasi data menggunakan Min-Max pada interval 0,1–0,9. Data dibagi menjadi 70% data pelatihan (Januari–Juli) dan 30% data pengujian (Agustus–Desember). Yang dapat dilihat pada Tabel 1 berikut :

Tabel 1 Variabel Input JST

No	Kode Variabel	Nama Variabel
1	X1	2019
2	X2	2020
No	Kode Variabel	Nama Variabel
3	X3	2021
4	X4	2022
5	X5	2023
6	X6	2024
7	X7	2025

Sistem diimplementasikan menggunakan PHP sebagai bahasa pemrograman sisi server, MySQL sebagai basis data, Apache/XAMPP sebagai web server, serta Bootstrap untuk antarmuka yang responsif. Proses pelatihan dilakukan secara iteratif menggunakan mekanisme feedforward dan backpropagation hingga nilai MSE mencapai target atau jumlah epoch maksimum tercapai.

## HASIL DAN PEMBAHASAN

### Data Penumpang

Data yang dikumpulkan mencakup jumlah penumpang kereta api rute Kisaran–Medan dari Januari 2019 hingga Desember 2025. Data menunjukkan tren peningkatan secara keseluruhan dari 2019 ke 2025, dengan penurunan signifikan pada 2020–2021 akibat pandemi COVID-19. Nilai tertinggi tercatat pada November 2025 sebesar 874.200 penumpang, sedangkan terendah pada Januari 2021 sebesar 48.620 penumpang. yang dapat dilihat pada Tabel 2 berikut:

Tabel 2 Data Jumlah Penumpang Kereta Api Rute Kisaran–Medan Per Bulan

No	Bulan	2019	2020	2021	2022	2023	2024	2025
1	Jan	245.321	521.430	48.620	132.540	298.450	325.700	648.200
2	Feb	267.540	598.200	52.310	148.730	332.610	357.400	705.100
3	Mar	289.430	642.870	58.740	156.240	365.900	389.200	748.600
4	Apr	251.870	615.300	54.120	149.860	341.700	371.500	712.400
5	Mei	310.540	671.420	62.350	167.450	389.420	418.300	801.500
6	Jun	278.650	623.150	57.180	152.630	354.870	392.700	763.900
7	Jul	324.780	702.540	64.890	176.200	401.230	439.100	856.400
8	Agu	295.430	668.730	60.240	165.430	382.540	421.600	829.500
9	Sep	281.560	637.210	56.370	154.800	361.200	398.500	781.300
No	Bulan	2019	2020	2021	2022	2023	2024	2025
10	Okt	256.340	589.740	51.780	143.520	336.840	369.200	726.400
11	Nov	301.870	653.980	61.150	171.640	395.430	432.800	874.200
12	Des	289.100	765.601	57.976	167.375	443.167	535.796	874.012

**Normalisasi Data**

Data penumpang dinormalisasi ke interval 0,1–0,9 menggunakan metode Min-Max agar sesuai dengan rentang fungsi aktivasi Sigmoid Biner. Persamaan normalisasi yang digunakan:

$$x' = 0,8 \times (x - x_{\min}) / (x_{\max} - x_{\min}) + 0,1$$

Dimana  $x'$  = nilai ternormalisasi,  $x$  = nilai asli,  $x_{\min}$  = nilai terkecil,  $x_{\max}$  = nilai terbesar. Nilai  $x_{\min}$  dan  $x_{\max}$  ditentukan per variabel input: X1(2019)

min=245.321, max=324.780; X2(2020)  
min=521.430, max=765.601; X3(2021)  
min=48.620, max=64.890; X4(2022)  
min=132.540, max=176.200; X5(2023)  
min=298.450, max=443.167; X6(2024)  
min=325.700, max=535.796; X7(2025)  
min=648.200, max=874.200; Target  
min=589.740, max=996.320.

Hasil normalisasi seluruh data beserta pembagian data pelatihan dan pengujian ditampilkan pada Tabel 3 berikut:

**Tabel 3 Hasil Normalisasi Seluruh Data Penumpang Kereta Api**

No	Bulan	X1	X2	X3	X4	X5	X6	X7	Target
<b>Data Pelatihan (70% = 7 Data)</b>									
1	Januari	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,7605
2	Februari	0,3237	0,3515	0,2814	0,3967	0,2888	0,2207	0,3014	0,1166
3	Maret	0,5441	0,4979	0,5976	0,5343	0,4729	0,3418	0,4554	0,2045
4	April	0,1659	0,4076	0,3704	0,4174	0,3391	0,2744	0,3273	0,9000
5	Mei	0,7566	0,5914	0,7751	0,7397	0,6029	0,4526	0,6427	0,2607
6	Juni	0,4356	0,4333	0,5209	0,4681	0,4119	0,3551	0,5096	0,4427
7	Juli	0,9000	0,6934	0,9000	0,9000	0,6682	0,5318	0,8370	0,3219
<b>Data Pengujian (30% = 5 Data)</b>									
8	Agustus	0,6045	0,5826	0,6714	0,7027	0,5649	0,4652	0,7418	0,8729
9	Septembe	0,4649	0,4793	0,4811	0,5079	0,4469	0,3772	0,5712	0,4769
10	Oktober	0,2109	0,3238	0,2554	0,3012	0,3122	0,2656	0,3768	0,1000
11	Novembe	0,6693	0,5343	0,7161	0,8164	0,6361	0,5078	0,9000	0,2264
12	Desember	0,5408	0,9000	0,5600	0,7383	0,9000	0,9000	0,8993	0,2528

**Inisialisasi Bobot dan Parameter JST**

Bobot awal diberikan secara acak dengan nilai relatif kecil pada rentang [-0,5; 0,5]. Parameter pelatihan yang digunakan: arsitektur 7-5-1, learning rate

( $\alpha$ ) = 0,25, maksimum epoch = 1000, dan fungsi aktivasi Sigmoid Biner untuk hidden layer serta Identitas untuk output layer.

**Tabel 4 Bobot Awal dari Input Layer Menuju Hidden Layer**

Bobot Input	Z1	Z2	Z3	Z4	Z5
X1 → V1j	-0,4826	-0,3645	-0,4339	0,4164	0,4944
X2 → V2j	-0,4819	0,0832	-0,2581	0,1511	-0,4187
X3 → V3j	0,1704	0,2085	-0,3700	0,2605	-0,3930
X4 → V4j	0,1908	-0,2165	-0,2321	-0,0245	0,0162

X5 → V5j	-0,1559	0,4984	-0,4962	0,4286	0,3575
X6 → V6j	-0,0738	0,3643	-0,1406	0,4993	-0,1386
<b>Bobot Input</b>	<b>Z1</b>	<b>Z2</b>	<b>Z3</b>	<b>Z4</b>	<b>Z5</b>
X7 → V7j	-0,1259	-0,1265	0,2977	0,4588	-0,2821

Tabel 5 Nilai Bias Awal dari Input Layer Menuju Hidden Layer

<b>V01</b>	<b>V02</b>	<b>V03</b>	<b>V04</b>	<b>V05</b>
-0,4493	-0,3228	-0,3675	0,3076	0,2809

Tabel 6 Bobot dan Bias Awal dari Hidden Layer Menuju Output Layer

<b>Bobot</b>	<b>B2/W0</b>	<b>W1</b>	<b>W2</b>	<b>W3</b>	<b>W4</b>	<b>W5</b>
Y (Output)	-0,2793	-0,4541	0,2448	-0,1718	0,0340	0,3857

**Proses Pelatihan (Feedforward dan Backpropagation)**

Tahap feedforward adalah perambatan sinyal maju dari input layer ke hidden layer kemudian ke output layer.

Persamaan yang digunakan:

$$z_{in}(j) = v0(j) + \sum(x_i \times v_{ij})$$

...(Persamaan 2)

$$z(j) = 1 / (1 + e^{(-z_{in}(j))})$$

...(Persamaan 3)

$$y_{in}(k) = w0 + \sum(z(j) \times w_j) ; y(k) = y_{in}(k)$$

...(Persamaan 4 & 5)

Sebagai contoh, untuk data ke-1 (Januari, x1=x2=...=x7=0,1; Target=0,7605) pada epoch ke-1:

$$z_{in}(1) = -0,4493 + (0,1 \times 0,4826) + \dots + (0,1 \times -0,1259) = -0,54519 \rightarrow z(1) = 0,36698$$

$$z_{in}(2) = -0,3228 + (0,1 \times -0,3645) + \dots + (0,1 \times -0,1265) = -0,27811 \rightarrow z(2) = 0,43092$$

$$z_{in}(3) = -0,3675 + (0,1 \times -0,4339) + \dots + (0,1 \times 0,2977) = -0,53082 \rightarrow z(3) = 0,37033$$

$$z_{in}(4) = 0,3076 + (0,1 \times 0,4164) + \dots + (0,1 \times 0,4588) = 0,52662 \rightarrow z(4) = 0,62869$$

$$z_{in}(5) = 0,2809 + (0,1 \times 0,4944) + \dots + (0,1 \times -0,2821) = 0,24447 \rightarrow z(5) = 0,56081$$

$$y_{in}(1) = -0,2793 + (0,36698 \times -0,4541) + (0,43092 \times 0,2448) + (0,37033 \times -0,1718) + (0,62869 \times 0,0340) + (0,56081 \times 0,3857) = -0,16640$$

Rangkuman hasil feedforward untuk seluruh 7 data pelatihan pada epoch ke-1 ditampilkan pada Tabel 7:

Tabel 7 Rangkuman Hasil Feedforward Epoch ke-1

No	Bulan	Target	z_in(1)	z(1)	Output (y)	Error	Total Error
1	Januari	0,7605	-0,54519	0,36698	-0,16640	0,92690	0,85913
2	Februari	0,1166	-0,78026	0,31426	0,37656	-0,25996	0,92671
No	Bulan	Target	z_in(1)	z(1)	Output (y)	Error	Total Error
3	Maret	0,2045	-0,92644	0,28365	0,25826	-0,05376	0,92961
4	April	0,9000	-0,71624	0,32822	0,18960	0,71040	1,43428
5	Mei	0,2607	-1,09257	0,25113	0,65491	-0,39421	1,58968
6	Juni	0,4427	-0,87636	0,29393	0,38400	0,05870	1,59313

7	Juli	0,3219	-1,17921	0,23519	0,45344	-0,13154	1,61043
---	------	--------	----------	---------	---------	----------	---------

MSE = total\_error / n = 1,61043 / 7 = 0,23006 ... (Persamaan 6)

Tahap Backpropagation menyebarkan error dari output layer ke hidden layer untuk memperbarui bobot dan bias. Faktor perubahan bobot output layer untuk data ke-1:

$$d\_net(j) = error \times w(j) \quad \dots(\text{Persamaan 7})$$

$$d(j) = d\_net(j) \times z(j) \times (1 - z(j))$$

... (Persamaan 8)

$$d\_net(1) = -0,42090 \rightarrow d(1) = -0,09778$$

$$d\_net(2) = 0,22691 \rightarrow d(2) = 0,05563$$

$$d\_net(3) = -0,15924 \rightarrow d(3) = -0,03713$$

$$d\_net(4) = 0,03151 \rightarrow d(4) = 0,00736$$

$$d\_net(5) = 0,35750 \rightarrow d(5) = 0,08805$$

Pembaharuan bobot menggunakan persamaan:

$$w_{ij}(\text{baru}) = w_{ij}(\text{lama}) + \Delta w_{ij} ; w_j(\text{baru}) = w_j(\text{lama}) + \Delta w_j \quad \dots(\text{Persamaan 9 \& 10})$$

Proses pembaharuan bobot dan bias dilakukan untuk semua data pelatihan (data ke-1 hingga ke-7) dalam setiap epoch, lalu diulang hingga kondisi berhenti terpenuhi. Pada penelitian ini, proses pelatihan berlangsung selama 882 epoch dengan nilai MSE epoch 1 sebesar 0,23006 yang terus menurun hingga konvergen.

**Tabel 8 Perkembangan Nilai MSE Selama Proses Pelatihan**

Epoch	Total Error	MSE
1	1,61043	0,23006
50	(proses iterasi)	(menurun)
100	(proses iterasi)	(menurun)
200	(proses iterasi)	(menurun)
500	(proses iterasi)	(menurun)
882	(konvergen)	(tercapai)

**Pengujian Jaringan dan Hasil Prediksi**

Setelah pelatihan selesai pada epoch ke-740, pengujian dilakukan menggunakan data uji (Agustus–Desember) dengan bobot dan bias optimal yang telah diperoleh. Hasil prediksi yang masih dalam bentuk ternormalisasi didenormalisasi menggunakan persamaan:  $x_i = ((x_p - 0,1) \times (x_{max} - x_{min}) / 0,8) + x_{min} \quad \dots(\text{Persamaan 11})$

Dimana  $x_{max} = 996.320$  dan  $x_{min} = 589.740$  (batas nilai target). Tingkat akurasi prediksi dihitung menggunakan persamaan:

$$\text{Akurasi (\%)} = (1 - |Data \text{ Aktual} - Data \text{ Prediksi}| / Data \text{ Aktual}) \times 100\% \quad \dots(\text{Persamaan 12})$$

**Tabel 9 Hasil Akhir Pengujian Jaringan Saraf Tiruan Backpropagation**

No	Bulan	D1	D2	D3	D4	D5	D6	D7	Prediksi 2026	Target
1	Jan	245.321	521.430	48.620	132.540	298.450	325.700	648.200	917.826	925.430
2	Feb	267.540	598.200	52.310	148.730	332.610	357.400	705.100	621.969	598.200
3	Mar	289.430	642.870	58.740	156.240	365.900	389.200	748.600	647.271	642.870
4	Apr	251.870	615.300	54.120	149.860	341.700	371.500	712.400	999.728	996.320
5	Mei	310.540	671.420	62.350	167.450	389.420	418.300	801.500	656.019	671.420
6	Juni	278.650	623.150	57.180	152.630	354.870	392.700	763.900	749.396	763.900
7	Juli	324.780	702.540	64.890	176.200	401.230	439.100	856.400	706.224	702.540
8	Agus	295.430	668.730	60.240	165.430	382.540	421.600	829.500	750.151	982.540
9	Sep	281.560	637.210	56.370	154.800	361.200	398.500	781.300	702.739	781.300
10	Okt	256.340	589.740	51.780	143.520	336.840	369.200	726.400	868.749	589.740
11	Nov	301.870	653.980	61.150	171.640	395.430	432.800	874.200	777.791	653.980
12	Des	289.100	765.601	57.976	167.375	443.167	535.796	874.012	951.694	667.375

No	Bulan	D1	D2	D3	D4	D5	D6	D7	Hasil Prediksi 2026	Target
1	Januari	245321	521430	48620	132540	298450	325700	648200	917826	925430
2	Februari	267540	598200	52310	148730	332610	357400	705100	621969	598200
3	Maret	289430	642870	58740	156240	365900	389200	748600	647271	642870
4	April	251870	615300	54120	149860	341700	371500	712400	999728	996320
5	Mei	310540	671420	62350	167450	389420	418300	801500	656019	671420
6	Juni	278650	623150	57180	152630	354870	392700	763900	749396	763900
7	Juli	324780	702540	64890	176200	401230	439100	856400	706224	702540
8	Agustus	295430	668730	60240	165430	382540	421600	829500	750151	982540
9	September	281560	637210	56370	154800	361200	398500	781300	702739	781300
10	Oktober	256340	589740	51780	143520	336840	369200	726400	868749	589740
11	November	301870	653980	61150	171640	395430	432800	874200	777791	653980
12	Desember	289100	765601	57976	167375	443167	535796	874012	951694	667375

**Gambar 1 Hasil Akhir Pengujian Jaringan Saraf Tiruan Backpropagation Menggunakan Sistem**

**SIMPULAN**

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat ditarik kesimpulan sebagai berikut:

Penerapan Jaringan Syaraf Tiruan dengan algoritma Backpropagation

berhasil diterapkan untuk memprediksi jumlah penumpang kereta api rute Kisaran–Medan. Model dibangun menggunakan arsitektur 7-5-1 dengan tujuh neuron input (data tahun 2019–2025), lima neuron hidden layer, dan satu neuron output, dengan learning rate 0,25. Data penumpang dinormalisasi menggunakan metode Min-Max ke interval 0,1–0,9, dan proses pelatihan berhenti pada epoch ke-740 saat target kesalahan tercapai.

Faktor-faktor yang mempengaruhi jumlah penumpang kereta api di Kota Kisaran teridentifikasi dari pola fluktuasi data historis, antara lain kondisi ekonomi masyarakat, ketersediaan layanan, hari libur nasional, musim mudik, serta infrastruktur transportasi pendukung. Faktor-faktor ini menyebabkan pola data bersifat non-linear dan kompleks.

Model prediksi mampu menghasilkan nilai prediksi yang mendekati data aktual pada sebagian besar bulan. Pada bulan Maret hasil prediksi sebesar 647.271 penumpang dengan data real 642.870 penumpang, bulan April sebesar 999.728 penumpang dengan data real 996.320 penumpang, dan bulan Juni sebesar 749.396 penumpang dengan data real 763.900 penumpang. Namun, beberapa bulan dengan lonjakan musiman masih menunjukkan selisih yang perlu ditingkatkan pada penelitian selanjutnya.

Hasil prediksi jumlah penumpang kereta api ini dapat digunakan sebagai bahan pertimbangan bagi PT Kereta Api Indonesia dan pemerintah daerah dalam menentukan strategi pelayanan, pengelolaan transportasi, serta pengambilan keputusan untuk meningkatkan kualitas layanan transportasi kereta api di masa mendatang.

#### DAFTAR PUSTAKA

Aldi Ramadani. (2025). Sistem Informasi Cuti Kepegawaian pada Rumah Sakit Umum Daerah Kabupaten Batu Bara. *Modem : Jurnal Informatika Dan*

*Sains Teknologi.*, 3(1), 67–75.

Aurellia, A., Nooriansyah, S., & Amrozi, Y. (2023). Informasi Produk Kreatif Daur Ulang Sampah. *JITET (Jurnal Informatika Dan Teknik Elektro Terapan)*, 13(3), 2303–0577.

Box, C. (2023). *Jurnal Widya Perancangan Aplikasi Sistem Informasi Penjualan Makanan Cepat Saji Berbasis Web Studi Kasus Kedai Jurnal Widya.* 4(April), 117–139.

Cahyono, Y. D., Widiati, L. W., Pramuningsih, S. I., Darat, P. A., Darat, P. A., & Development, A. W. (2025). *Pengolahan Data Teritorial Menggunakan.* 9(2), 2250–2256.

Engineering, I., Meri, R., Perdana, R. W., Studi, P., Informatika, M., Studi, P., & Komputer, T. (2022). *Jaringan syaraf tiruan menggunakan algoritma hebb rule untuk diagnosa penyakit kulit manusia.* 6(2), 78–87.

FAIZAL, M. I., INTAN, V. N., & FIRMANSYAH, R. (2021). Analisis Sistem Informasi Manajemen Bagi Pendidikan di Masa Pandemi Covid-19. *JEMSI (Jurnal Ekonomi, Manajemen, Dan Akuntansi)*, 7(1), 9–16.

Fifian Theresia Sibi, & Jim Lahallo. (2025). Rancang Bangun Sistem Database Tilang Kendaraan Angkutan Umum dan Angkutan Barang Dinas Perhubungan Kota Jayapura. *Modem : Jurnal Informatika Dan Sains Teknologi.*, 3(1), 98–105.

Harefa, E., Budiman, T., & Budi Yulianto, A. (2025). Pengembangan Sistem Informasi Buku Berbasis Web Untuk Perpustakaan Sma Budi Mulia Bogor. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(5), 9157

Hidayat, R., Toyib, R., Apridiansyah, Y., & Reswan, Y. (2025). Klasifikasi Citra Daun Herbal Dengan Khasiatnya Untuk Pengobatan Menggunakan Jaringan Syaraf Tiruan (Backpropagation). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 5571–5577.

Irmansyah, D. (2025). Jurnal JISILKOM (Jurnal Inovasi Sistem Informasi &

Ilmu Komputer) Prediksi Penyakit  
Paru-Paru Menggunakan Jaringan  
Saraf Tiruan Dengan Metode  
Backpropagation. *Jurnal*

*JISILKOM*, 3(1), 3025–4868.  
Kamilia, H. (2025). *Pengunjung Laundry  
Onty Pada Kota Kisaran Timur*.  
9(2), 2181–2188.