

Penerapan Jaringan Syaraf Tiruan Dalam Memprediksi Tingkat Jumlah Perjalanan Wisatawan Nusantara Menurut Provinsi Tujuan Menggunakan Algoritma Backpropagation Conjugate Gradient

Ginanti Riski¹, Victor Asido Elyakim Panggabean²

¹STIKOM Tunas Bangsa, Pematangsiantar – Indonesia

²Universitas HKBP Nommensen, Pematangsiantar – Indonesia

Article Info

Article history:

Received Feb 06, 2024

Revised Feb 09, 2024

Accepted Feb 10, 2024

Kata Kunci:

JST

Prediksi Tingkat Jumlah
Perjalanan Wisatawan
Menurut Provinsi Tujuan
Backpropagation

Keywords:

JST, Prediction

Level of Tourist Travel

By Destination Province

Backpropagation Conjugate
Gradient

ABSTRAK

Jumlah kedatangan wisatawan domestik bervariasi setiap tahunnya untuk setiap provinsi tujuan di Indonesia, mengalami kenaikan dan penurunan. Sebagai contoh, di provinsi unggulan seperti Bali, terjadi kenaikan yang konsisten setiap tahun. Pada tahun 2020, jumlah wisatawan sebanyak 8.819.530, naik menjadi 9.985.110 pada tahun 2021, 14.259.714 pada tahun 2022, dan 15.173.617 pada tahun 2023. Di sisi lain, provinsi Sumatera Utara mengalami kenaikan dari tahun 2020 hingga 2022 namun mengalami penurunan pada tahun 2023. Pada tahun 2020, terdapat 14.046.368 wisatawan, yang meningkat menjadi 17.758.183 pada tahun 2021, 23.204.456 pada tahun 2022, dan turun menjadi 2.053.271 pada tahun 2023. Fenomena ini menjadi dasar penelitian saat ini, dengan tujuan memberikan data prediksi kepada pemerintah daerah. Tujuannya adalah untuk mengantisipasi penurunan kedatangan wisatawan dengan meningkatkan kualitas wilayah masing-masing pada tahun-tahun berikutnya. Untuk memprediksi tingkat perjalanan wisatawan domestik menurut provinsi, penelitian ini menggunakan metode JST Algoritma Backpropagation conjugate gradient. MATLAB (versi 7.13 R2011b) digunakan sebagai alat, menggunakan lima arsitektur model (2-3-1, 2-7-1, 2-15-1, 2-45-1, dan 2-8-17-1) untuk menguji data untuk estimasi/prediksi. Model terbaik yaitu 2-8-17-1, mencapai ketepatan 94%, dengan 170 iterasi dalam waktu tidak kurang dari 1 detik dan MSE 0,008118265. Dengan akurasi 94%, model ini akan digunakan untuk memprediksi jumlah perjalanan wisatawan ke Nusantara menurut provinsi tujuan pada tahun 2024.

ABSTRACT

The number of domestic tourist arrivals varies annually for each destination province in Indonesia, experiencing both increases and decreases. For example, in a leading province like Bali in 2020, the number of tourists was 8,819,530, rising to 9,985,110 in 2021, 14,259,714 in 2022, and 15,173,617 in 2023. On the other hand, North Sumatra province experienced an increase from 2020 to 2022 but decreased in 2023. In 2020, there were 14,046,368 tourists, which increased to 17,758,183 in 2021, 23,204,456 in 2022, and decreased to 2,053,271 in 2023. This phenomenon is the basis of the current research, with the aim of providing predictive data to the local government. The goal is to anticipate the decline in tourist arrivals by improving the quality of their respective regions in the following years. To predict the level of domestic tourist trips by province, this research uses the JST method Backpropagation conjugate gradient algorithm. MATLAB (version 7.13 R2011b) is used as a tool, using five model architectures to test the data for estimation/prediction. The best model, 2-8-17-1, achieved 94% accuracy, with 170 iterations in no less than 1 second and an MSE of 0.008118265. With 94% accuracy, this model will be used to predict the number of tourist trips to the archipelago by destination province in 2024.

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license.



Corresponding Author:

Ginanti Riski

STIKOM Tunas Bangsa Pematangsiantar,

Jalan Sudirman BLOK A NO. 1-3, Kota Pematangsiantar, Sumatera Utara, 21143, Indonesia.

Email: ginantiriski@gmail.com

1. PENDAHULUAN

Pariwisata di Indonesia telah menjadi tulang punggung ekonomi nasional, memberikan kontribusi signifikan terhadap pendapatan negara dan pertumbuhan ekonomi secara keseluruhan (Ritchie & Crouch, 2003). Dengan keindahan alam, warisan budaya yang kaya, dan keragaman destinasi, Indonesia menarik perhatian wisatawan dari seluruh dunia (Ritchie & Crouch, 2003). Penting untuk memahami dan meramalkan pola perjalanan wisatawan agar pemerintah dan pelaku industri dapat merencanakan pengembangan destinasi dan meningkatkan pengalaman wisatawan (Song, Witt, & Li, 2003). Dalam era teknologi informasi dan digital, penerapan teknologi canggih, seperti Jaringan Syaraf Tiruan (JST) dengan algoritma Backpropagation, menjadi esensial untuk meningkatkan akurasi prediksi (Haykin, 2009). Dengan kekayaan alamnya yang melimpah, Indonesia memiliki peluang besar untuk terus tumbuh sebagai tujuan pariwisata utama (Ritchie & Crouch, 2003). Pertumbuhan industri pariwisata membutuhkan pengelolaan yang lebih canggih dan akurat (Ritchie & Crouch, 2003). Prediksi jumlah perjalanan wisatawan Nusantara menurut provinsi menjadi krusial untuk menyusun strategi pemasaran, alokasi sumber daya, dan pengembangan infrastruktur pariwisata (Pratiwi & Kusumaningrum, 2016). Penggunaan algoritma Backpropagation dalam JST dapat meningkatkan ketepatan prediksi dan membantu manajemen destinasi secara lebih efektif (Haykin, 2009).

JST menjadi solusi yang menjanjikan dalam memodelkan pola kompleks perjalanan wisatawan (Haykin, 2009). Keunggulan utama JST terletak pada kemampuannya untuk memahami hubungan non-linear dan kompleks dalam data perjalanan wisatawan (Zhang, 2003). Algoritma Backpropagation merupakan metode pembelajaran yang penting dalam meningkatkan kemampuan prediksi JST (Rumelhart, Hinton, & Williams, 1986). Backpropagation memungkinkan sistem belajar dari kesalahan dan menyesuaikan diri untuk meningkatkan akurasi prediksi (Haykin, 2009). Prediksi jumlah perjalanan wisatawan memiliki dampak langsung pada keberhasilan industri pariwisata (Song et al., 2003). Menurut Pratiwi dan Kusumaningrum (2016), prediksi yang akurat membantu pemerintah dan pelaku industri membuat keputusan yang lebih tepat. Informasi ini mendukung perencanaan program pariwisata yang efektif, alokasi anggaran yang bijaksana, dan pengembangan destinasi yang berkelanjutan (Ritchie & Crouch, 2003).

Penelitian ini bertujuan menerapkan Jaringan Saraf Tiruan (JST) dengan menggunakan algoritma Backpropagation untuk meramalkan jumlah perjalanan wisatawan Nusantara menurut provinsi (Santoso & Ferdiansyah, 2018). Dengan melakukan analisis data yang mendalam, diharapkan bahwa hasil prediksi yang dihasilkan dapat memberikan wawasan yang lebih komprehensif tentang perilaku wisatawan di setiap wilayah, memberikan peluang bagi pemerintah dan pemangku kepentingan industri untuk membuat keputusan yang lebih terinformasi (Song et al., 2003). Signifikansi penelitian ini terletak pada kontribusinya terhadap pengembangan industri pariwisata di Indonesia (Nasution, 2019). Dengan memiliki model prediksi yang andal, pemerintah dapat lebih efektif merencanakan program pariwisata dan alokasi anggaran (Pratiwi & Kusumaningrum, 2016). Para pelaku industri juga dapat mengoptimalkan sumber daya mereka, meningkatkan kualitas layanan, dan merancang strategi pemasaran yang lebih efektif (Ritchie & Crouch, 2003).

Metode penelitian ini melibatkan pengumpulan data historis perjalanan wisatawan dari berbagai provinsi di Indonesia (Adiwijaya & Irnawati, 2019). Data ini akan digunakan sebagai input untuk melatih model JST dengan algoritma Backpropagation (Haykin, 2009). Proses pelatihan ini akan memungkinkan sistem untuk menyesuaikan bobot dan bias agar dapat menghasilkan prediksi yang akurat (Rumelhart et al., 1986). JST menawarkan keunggulan dalam memproses data yang kompleks dan non-linear, yang umumnya ditemui dalam tren perjalanan wisatawan (Haykin, 2009). Kelebihan lainnya adalah kemampuan JST untuk belajar dari pengalaman masa lalu, sehingga semakin banyak data yang dimasukkan, semakin baik prediksi yang dihasilkan (Zhang, 2003). Fleksibilitas JST juga memungkinkan penyesuaian model sesuai dengan karakteristik unik dari setiap provinsi di Indonesia (Song et al., 2003).

Namun demikian, penggunaan JST dalam prediksi perjalanan wisatawan tidak terlepas dari tantangan (Pratiwi & Kusumaningrum, 2016). Kualitas data yang tidak memadai dan fluktuasi ekonomi yang tidak

terduga dapat memengaruhi akurasi prediksi (Haykin, 2009). Oleh karena itu, penting untuk memperhatikan keterbatasan dan melakukan validasi terhadap model yang dikembangkan (Zhang, 2003). Penerapan algoritma Backpropagation Conjugate Gradient menjadi langkah inovatif dalam meningkatkan kemampuan prediktif JST (Haykin, 2009). Dengan memanfaatkan teknik ini, diharapkan dapat mencapai tingkat akurasi yang lebih tinggi dalam memprediksi perjalanan wisatawan (Santoso & Ferdiansyah, 2018).

Penerapan JST dengan algoritma Backpropagation Conjugate Gradient dalam memprediksi tingkat jumlah perjalanan wisatawan Nusantara menurut provinsi merupakan langkah inovatif untuk meningkatkan manajemen dan pengembangan sektor pariwisata di Indonesia (Pratiwi & Kusumaningrum, 2016). Dengan pendekatan ini, diharapkan dapat dibentuk landasan prediksi yang handal, memberikan kontribusi positif terhadap pertumbuhan industri pariwisata, dan menciptakan pengalaman wisatawan yang lebih baik (Santoso & Ferdiansyah, 2018). Penelitian ini memiliki implikasi positif yang signifikan untuk pengambilan keputusan di tingkat pemerintahan dan industri pariwisata, serta sebagai kontribusi bagi literatur penelitian di bidang prediksi pariwisata.

Walaupun beberapa penelitian sebelumnya telah mengulas pemanfaatan Jaringan Saraf Tiruan (JST) dalam meramalkan perjalanan wisatawan, terdapat kekurangan yang dapat diidentifikasi (Santoso & Ferdiansyah, 2018). Sebagian besar penelitian tersebut cenderung bersifat umum dalam memprediksi jumlah total wisatawan atau tren pariwisata secara keseluruhan tanpa mempertimbangkan perbedaan tingkat provinsi di Indonesia. Selanjutnya, penelitian ini seharusnya mengisi kesenjangan dengan konsentrasi yang lebih jelas pada tingkat umum, memberikan pemahaman yang lebih mendalam tentang fluktuasi perjalanan wisatawan di seluruh nusantara.

2. METODE PENELITIAN

2.1. Data Penelitian

Penelitian ini memanfaatkan data yang disediakan oleh Badan Pusat Statistik (BPS – *Statistics Indonesia*) mengenai jumlah perjalanan wisatawan domestik menurut provinsi tujuan mulai tahun 2020 hingga 2023.

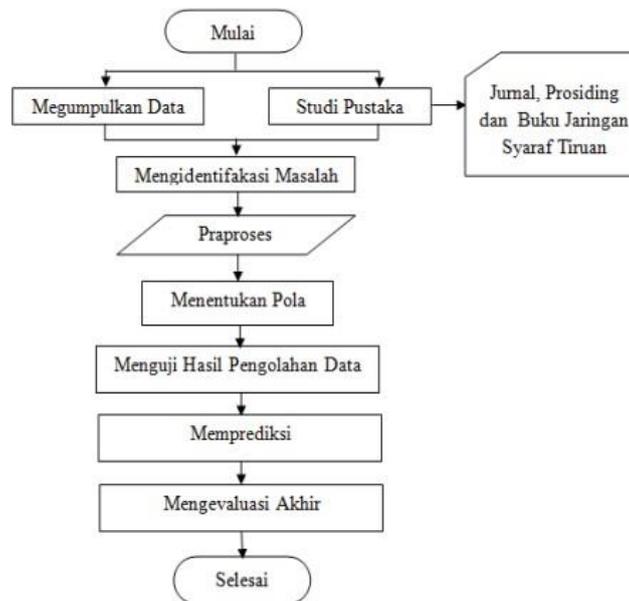
Tabel 1. Jumlah Perjalanan Wisatawan Nusantara Menurut Provinsi Tujuan

Provinsi	Jumlah Perjalanan Wisatawan Nusantara Menurut Provinsi Tujuan (Perjalanan)			
	2020	2021	2022	2023
Aceh	4142179	5534405	6954578	6044779
Sumatera Utara	14046368	17758183	23204456	20532719
Sumatera Barat	7892822	9603912	12339263	11315449
Riau	5505722	6143269	8404236	8142026
Jambi	2684562	3047167	3780983	3416089
Sumatera Selatan	5830094	6827337	8492364	8037321
Bengkulu	1520357	1770693	2113649	1879000
Lampung	8525722	9176866	10925704	10262614
Kep. Bangka Belitung	966097	1063989	1578407	1671218
Kep. Riau	745581	835672	1511354	1656946
Dki Jakarta	30914200	37634468	56008041	44845453
Jawa Barat	89881532	96315313	123531743	113517757
Jawa Tengah	132432379	147674185	110345715	89926347
Di Yogyakarta	19591482	22834000	25743590	23158305
Jawa Timur	127101662	159077924	200548137	160324462
Banten	28841977	36733930	38597642	31606599
Bali	8819530	9985110	14259714	15173617
Nusa Tenggara Barat	3372698	3138788	4091259	9517389
Nusa Tenggara Timur	2293682	3108815	3849353	3613889
Kalimantan Barat	1854608	2411392	3279863	3280250
Kalimantan Tengah	1903804	1974792	2683604	2656438
Kalimantan Selatan	4133592	4282529	5310737	5100568
Kalimantan Timur	2404852	2492841	5431717	5603104
Kalimantan Utara	281667	308841	354580	393694
Sulawesi Utara	2480807	3732957	4421855	3874059
Sulawesi Tengah	1571622	2026911	6453017	4746536
Sulawesi Selatan	9215054	10228085	28599212	19122124
Sulawesi Tenggara	1983012	2581155	12783046	9232679
Gorontalo	848058	1188830	1478813	1300721

Provinsi	Jumlah Perjalanan Wisatawan Nusantara Menurut Provinsi Tujuan (Perjalanan)			
	2020	2021	2022	2023
Sulawesi Barat	850899	1082502	4234501	2896548
Maluku	403048	639765	612567	619449
Maluku Utara	502711	672705	1511241	1255137
Papua Barat	342490	485005	469876	437800
Papua	686522	927123	959876	924273

Sumber : Badan Pusat Statistik (BPS – Statistics Indonesia)

2.2. Flowchart Penelitian



Gambar 1. Flowchart Penelitian

Dengan mempertimbangkan gambaran umum alur pemeriksaan yang diilustrasikan dalam Gambar 1, masing-masing tahap dapat dijelaskan sebagai berikut :

1. Mengumpulkan Data
Dalam langkah ini, informasi diperoleh dari Badan Pusat Statistik (BPS – *Statistics* Indonesia).
2. Studi Pustaka
Pemeriksaan pustaka merupakan tahap awal dalam rangkaian penelitian ini. Penelitian penulisan dipimpin untuk melengkapi informasi penting dan memahami hipotesis yang berkaitan dengan pemeriksaan.
3. Mengidentifikasi Masalah
Identifikasi masalah selesai setelah informasi dikumpulkan. Proses ini mencakup pemilihan dataset yang sesuai setelah semua data diperoleh, yang nantinya akan ditangani dengan berfokus pada bobot yang telah ditentukan sebelumnya.
4. Praproses
Selama fase prapemrosesan, beberapa atribut himpunan data diubah ke tipe data yang berbeda. Maksudnya adalah untuk mempermudah pemahaman terhadap konten rekaman dan melakukan pemilihan untuk memastikan konsistensi data, mengatasi nilai yang hilang, serta menghapus data yang berlebihan.
5. Menentukan Model
Hasil dari tahap ini adalah beberapa model jaringan saraf tiruan dengan menggunakan metode Backpropagation untuk menentukan pola yang relevan.
6. Menguji Hasil Pengolahan Data
Setelah model ditetapkan, langkah berikutnya melibatkan awal dari proses pengelolaan informasi dengan menggunakan bahasa pemrograman Matlab R2011b (7.13).
7. Memprediksi
Metode Backpropagation, yang dianggap paling akurat, digunakan dalam fase prediksi untuk

membandingkan angka dengan model Jaringan Saraf Tiruan.

8. Mengevaluasi Akhir

Langkah terakhir mencakup penilaian terakhir untuk mengevaluasi apakah konsekuensi dari penanganan informasi sesuai dengan asumsi yang telah ditetapkan. Penilaian ini berencana untuk menjamin ketepatan model yang telah dibuat.

2.3. Normalisasi Data

Langkah-langkah normalisasi digunakan untuk mempermudah proses sebelum fase pelatihan dan pengujian data dimulai. Pendekatan standarisasi informasi, seperti yang digambarkan oleh Rumelhart, Hinton, dan Williams (1986) dalam "Learning Portrayals by Back-Spreading Blunders" in Nature, 323 (6088), 533-536, menggunakan rumus :

$$x^1 = \frac{0,8(x-a)}{b-a} + 0,1 \tag{1}$$

Informasi :

- x^1 = Hasil Normalisasi Data
- x = Nilai Data yang Memerlukan Normalisasi
- a = Nilai Terendah dalam Data
- b = Nilai Tertinggi dalam Data

3. HASIL DAN PEMBAHASAN

3.1 Hasil Normalisasi Data

Dataset akan dibagi menjadi dua bagian sebelum standarisasi atau perhitungan, menjadi informasi persiapan spesifik dan informasi pengujian. Informasi persiapan mencakup rentang waktu dari 2020 hingga 2021 dengan fokus harapan pada 2022, sedangkan informasi pengujian mencakup periode 2021 hingga 2022 dengan fokus penilaian pada 2023.

Tabel 2. Hasil Normalisasi Data Pelatihan

Provinsi	Jumlah Perjalanan Wisatawan Nusantara Menurut Provinsi Tujuan (Perjalanan)		
	2020	2021	Target
Aceh	0,11542	0,12098	0,12666
Sumatera Utara	0,15499	0,16981	0,19157
Sumatera Barat	0,13040	0,13724	0,14817
.....
.....
.....
Sulawesi Barat	0,10227	0,10320	0,11579
Maluku	0,10048	0,10143	0,10132
Maluku Utara	0,10088	0,10156	0,10491
Papua Barat	0,10024	0,10081	0,10075
Papua	0,10162	0,10258	0,10271

Untuk konsekuensi standarisasi informasi pengujian harus terlihat dalam tabel terlampir berikut ini.

Tabel 3. Hasil Normalisasi Data Pengujian

Provinsi	Jumlah Perjalanan Wisatawan Nusantara Menurut Provinsi Tujuan (Perjalanan)		
	2021	2022	Target
Aceh	0,12088	0,12655	0,12292
Sumatera Utara	0,16971	0,19147	0,18080
Sumatera Barat	0,13714	0,14806	0,14397
.....
.....
.....

Provinsi	Jumlah Perjalanan Wisatawan Nusantara Menurut Provinsi Tujuan (Perjalanan)		
	2021	2022	Target
Sulawesi Barat	0,10309	0,11568	0,11034
Maluku	0,10132	0,10121	0,10124
Maluku Utara	0,10145	0,10480	0,10378
Papua Barat	0,10070	0,10064	0,10052
Papua	0,10247	0,10260	0,10246

3.2 Pelatihan dan Pengujian

Pemeriksaan ini memanfaatkan lima model desain organisasi yang diterapkan pada proses pelatihan dan pengujian informasi, yakni 2-3-1, 2-7-1, 2-15-1, 2-45-1, dan 2-8-17-1. Dari kelima model tersebut, dipilih model optimal, yaitu model 2-8-17-1, yang terdiri dari dua input, tiga neuron di lapisan tersembunyi, dan satu lapisan output. Untuk mengimplementasikan kode program pelatihan dan pengujian, digunakan perintah sebagai berikut dalam lingkungan Matlab :

```
>> net = newff(minmax(P), [3,1], {'tansig','logsig'}, 'traincgp');
```

Perintah ini dimanfaatkan untuk membentuk jaringan Backpropagation yang terdiri dari tiga neuron pada lapisan tersembunyi dan satu neuron pada lapisan output. Fungsi aktivasi yang diterapkan adalah tansig (sigmoid bipolar) dan logsig (sigmoid logaritmik), dan untuk proses pelatihan menggunakan fungsi traincgp.

```
>> net.IW{1,1};
```

Berat utama yang digunakan untuk lapisan tersembunyi.

```
>> net.b{1};
```

Bias yang digunakan untuk layer tersembunyi.

```
>> net.LW{2,1};
```

Bobot kedua yang digunakan untuk layer keluaran.

```
>> net.b{2};
```

Bias yang digunakan untuk layer keluaran.

```
>> net.trainParam.epochs = 1000;
```

Perintah untuk menentukan jumlah iterasi (epochs) maksimum pelatihan.

```
>> net.trainParam.goal = 0.003;
```

Perintah untuk menentukan batas Mean Squared Error (MSE) agar iterasi dihentikan.

```
>> net.trainParam.Lr = 0.01;
```

Perintah untuk menentukan laju pembelajaran (Learning Rate).

```
>> net.trainParam.show = 25;
```

Perintah untuk menampilkan frekuensi perubahan MSE.

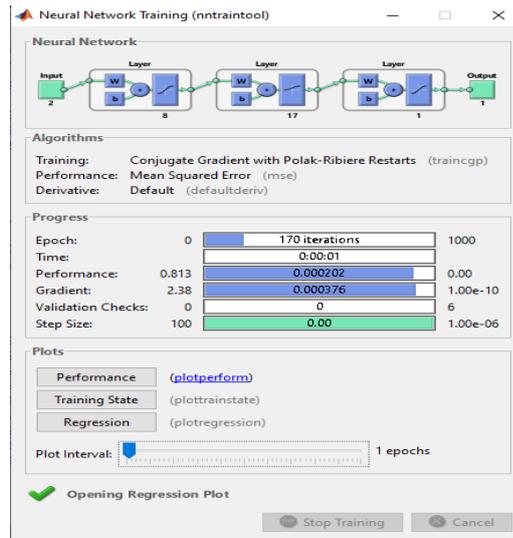
```
>> net = train(net, P, T);
```

Perintah ini digunakan untuk melakukan pelatihan terhadap jaringan.

```
>> [a, Pf, Af, e, Perf] = sim(net, P, [], [], T);
```

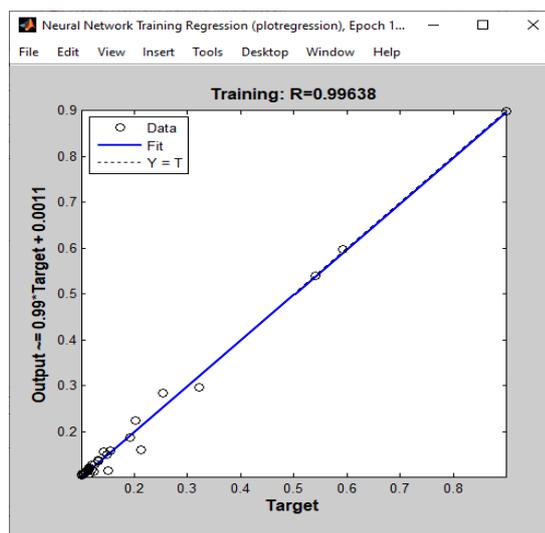
Perintah ini digunakan untuk melihat hasil yang dihasilkan oleh jaringan.

Pelatihan data pada struktur model 2-8-17-1 dengan menggunakan perangkat lunak Matlab dapat dilihat dalam ilustrasi berikut.



Gambar 2. Pelatihan Menggunakan Arsitektur 2-8-17-1

Gambar 2 mengindikasikan bahwa kualitas data pelatihan dapat dengan baik diinterpretasikan melaluistruktur model 2-8-17-1, yang mencapai sekitar 170 iterasi setiap interval 1 detik.



Gambar 3. Kinerja Pelatihan Menggunakan Model Arsitektur 2-8-17-1

Ilustrasi pada Gambar 3 menunjukkan bahwa pencapaian tertinggi dari persiapan dilakukan oleh model struktural 2-8-17-1, mencapai nilai sebesar 0,99638 pada iterasi ke-170. Informasi selengkapnya mengenai penyusunan tabel dan pengujian menggunakan desain model 2-8-17-1 dapat ditemukan dalam tabel berikut.

Tabel 4. Hasil Data Pelatihan dengan Model Arsitektur 2-8-17-1

No	Target	Output JST	Error	SSE	Akurasi
1	0,12666	0,12827	-0,00161	0,0000025889	1
2	0,19157	0,186589735	0,00498	0,0000247946	0
3	0,14817	0,150563254	-0,00240	0,0000057458	1
..
..
30	0,11579	0,10825546	0,00753	0,0000567738	0
31	0,10132	0,106217235	-0,00490	0,0000239649	1
32	0,10491	0,106382776	-0,00147	0,0000021639	1
33	0,10075	0,105534678	-0,00478	0,0000228756	1
34	0,10271	0,107527279	-0,00482	0,0000232136	1

Jumlah	0,0068630467	27
MSE	0,0002018543	79,41176471 (%)

Tabel 5. Hasil Data Pengujian dengan Model Arsitektur 2-8-17-1

No	Target	Output JST	Error	SSE	Akurasi
1	0,12292	0,13587	-0,01295	0,000167756	1
2	0,18080	0,204155786	-0,02336	0,000545547	1
3	0,14397	0,16046855	-0,01649	0,000272076	1
..
..
30	0,11034	0,123576168	-0,01324	0,000175237	1
31	0,10124	0,106092282	-0,00485	2,35354E-05	1
32	0,10378	0,109937025	-0,00616	3,79008E-05	1
33	0,10052	0,105405123	-0,00489	2,39112E-05	1
34	0,10246	0,10771786	-0,00526	2,76579E-05	1
			Jumlah	0,276020998	32
			MSE	0,008118265	94,11764706 (%)

Berdasarkan hasil penelitian, penjelasan dari 34 pola pada Tabel 3 dan Tabel 4 disajikan. Penjelasan ini disesuaikan dengan jumlah data yang digunakan. Nilai objektif berasal dari tabel standarisasi informasi pengujian tahun 2023, sementara nilai hasil diperoleh dari persiapan menggunakan aplikasi MATLAB dengan menggunakan rumus $[a, Pf, Af, e, Perf] = \text{sim}(\text{net}, PP, [], [], TT)$. Kesalahan diukur sebagai perbedaan antara tujuan dan hasil, sedangkan nilai SSE dihitung sebagai kuadrat kesalahan (\wedge : pangkat), dan SSE total adalah jumlah dari nilai SSE absolut. MSE dihitung dengan menggunakan rumus: SSE total dibagi dengan 34 (jumlah contoh), dan nilai 1 atau 0, yang menunjukkan hasil yang valid atau menyesatkan, diperoleh dengan menggunakan rumus $= IF(\text{error} \leq 0,02; 1; 0)$. Akurasi dihitung dengan membagi.

3.3 Penentuan Model Arsitektur Terbaik

Setelah mempersiapkan dan menguji data menggunakan model desain 2-3-1, 2-7-1, 2-15-1, 2-45-1, dan 2-8-17-1 dengan bantuan aplikasi Matlab dan Microsoft Excel, ditemukan bahwa model desain terbaik adalah 2-8-17-1 dengan tingkat ketepatan sebesar 94%, atau akurasi tertinggi dibandingkan dengan empat model lainnya. Oleh karena itu, dapat disimpulkan bahwa terdapat margin kesalahan yang cukup signifikan. Akurasi yang tercapai mengalami penurunan sebesar 6% dari tingkat akurasi maksimal (100%). Perbandingan umum dari kelima model desain dapat diuraikan sebagai berikut.

Tabel 6. Perbandingan Struktur Arsitektur yang Diterapkan

Perbandingan 5 Model Arsitektur				
Arsitektur	Epoch	Waktu	Pengujian	
			MSE	Akurasi
2-3-1	303	0:00:03	0,003450056	82%
2-7-1	378	0:00:03	0,010074159	76%
2-15-1	348	0:00:03	0,020058072	91%
2-45-1	248	0:00:02	0,018217041	88%
2-8-17-1	170	0:00:01	0,008118265	94%

3.4 Hasil Prediksi

Berikutnya, prediksi akan ditemukan dan diperoleh melalui penerapan model 2-8-17-1 menggunakan formula pengembalian nilai berikut.

Keterangan :

$$x_n = \frac{(x-0,1) \times (b-a)}{0,8} + a \quad (2)$$

x_n = Ouput dari Proses Restitusi Nilai
 x = Tujuan Prediksi
 a = Nilai Minimum dari Keseluruhan Dataset

b = Nilai Maksimum dari Keseluruhan Dataset
 0,8 dan 0,1 = Parameter Normalisasi Proses Restitusi Nilai

Proyeksi jumlah perjalanan wisatawan dalam negeri berdasarkan provinsi untuk tahun 2024, hasil dari rumus dalam persamaan di atas, tercantum dalam Tabel 6 berikut ini.

Tabel 7. Hasil Prediksi Jumlah Perjalanan Wisatawan Nusantara Menurut Provinsi

No	Provinsi	Data Real	Target	Target Prediksi	Prediksi (2024)
1	Aceh	6044779	0,128267656	0,13587	7564273
2	Sumatera Utara	20532719	0,200738715	0,204155786	21215837
3	Sumatera Barat	11315449	0,154632414	0,16046855	12482171
4	Riau	8142026	0,138758431	0,140338089	8457821
5	Jambi	3416089	0,115118517	0,120766639	4545225
6	Sumatera Selatan	8037321	0,138234679	0,143726179	9135146
7	Bengkulu	1879000	0,107429745	0,11301035	2994638
8	Lampung	10262614	0,149365961	0,158868118	12162223
9	Kep. Bangka Belitung	1671218	0,106390385	0,110246564	2442120
10	Kep. Riau	1656946	0,106318994	0,10989975	2372787
11	Dki Jakarta	44845453	0,322355008	0,471955632	74752631
12	Jawa Barat	113517757	0,665865165	0,913358452	162994996
13	Jawa Tengah	89926347	0,547857053	0,270691313	34517185
14	Di Yogyakarta	23158305	0,213872328	0,246422813	29665585
15	Jawa Timur	160324462	0,9	0,91329713	162982737
16	Banten	31606599	0,256132083	0,35118825	50609606
17	Bali	15173617	0,173931605	0,162744317	12937128
18	Nusa Tenggara Barat	9517389	0,145638223	0,121824646	4756735
19	Nusa Tenggara Timur	3613889	0,116107945	0,121118387	4615544
20	Kalimantan Barat	3280250	0,114439028	0,117913105	3974765
21	Kalimantan Tengah	2656438	0,111318618	0,115259632	3444300
22	Kalimantan Selatan	5100568	0,123544558	0,128155291	6022316
23	Kalimantan Timur	5603104	0,126058325	0,126627341	5716858
24	Kalimantan Utara	393694	0,1	0,104839923	1361260
25	Sulawesi Utara	3874059	0,117409358	0,124418989	5275379
26	Sulawesi Tengah	4746536	0,121773631	0,133985341	7187821
27	Sulawesi Selatan	19122124	0,193682686	0,30925508	42226601
28	Sulawesi Tenggara	9232679	0,144214056	0,188110359	18008141
29	Gorontalo	1300721	0,104537098	0,109956585	2384149
30	Sulawesi Barat	2896548	0,112519687	0,123576168	5106887
31	Maluku	619449	0,101129264	0,106092282	1611623
32	Maluku Utara	1255137	0,10430908	0,109937025	2380239
33	Papua Barat	437800	0,100220625	0,105405123	1474251
34	Papua	924273	0,102654043	0,10771786	1936598
	MAX	160324462			
	MIN	393694			
	MAX-MIN	159930768			

4. KESIMPULAN

Kesimpulan dari penelitian ini adalah :

- Setelah melewati tahap pelatihan dan pengujian menggunakan lima model arsitektur, yakni 2-3-1, 2-7-1, 2-15-1, 2-45-1, dan 2-8-17-1, ditemukan bahwa satu-satunya desain arsitektur yang optimal adalah model 2-8-17-1. Model ini mencapai tingkat akurasi paling tinggi, yakni 94%, dengan 170 iterasi selama 1 detik dan nilai Mean Squared Error (MSE) sebesar 0,008118265.
- Model struktur 2-8-17-1 dapat diterapkan untuk melakukan proyeksi jumlah perjalanan wisatawan dalam negeri berdasarkan provinsi untuk tahun 2024.

REFERENCES

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors.

- Nature, 323(6088), 533-536.
- Ritchie, J. R., & Crouch, G. I. (2003). *The Competitive Destination: A Sustainable Tourism Perspective*. CABI.
- Song, H., Witt, S. F., & Li, G. (2003). *Tourism Demand Modelling and Forecasting: Modern Econometric Approaches*. Butterworth-Heinemann.
- Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson.
- Pratiwi, R. A., & Kusumaningrum, D. (2016). Forecasting Tourist Arrival with Artificial Neural Network: A Case Study of Yogyakarta, Indonesia. *Procedia Computer Science*, 82, 177-183.
- Nasution, M. Y. (2019). The Impact of Tourism towards Economic Growth and Employment in Indonesia. *Journal of Economics and Behavioral Studies*, 11(6), 42-53.
- Santoso, I., & Ferdiansyah, F. (2018). Artificial Neural Network-Based Prediction Model for Tourist Arrivals in Bali. *Journal of Physics: Conference Series*, 1094, 012089.
- Adiwijaya, W., & Irnawati, D. (2019). Predicting Tourist Arrival in Indonesia Using Neural Network Model. In *Proceedings of the International Conference on Information Management and Technology (ICIMTech)* (pp. 1-6).
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Representations by Backpropagating Errors. *Nature*, 323(6088), 533-536.
- Zhang, G. P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175.
- Pratiwi, R. A., & Kusumaningrum, D. (2016). Factors Affecting International Tourist Arrival in Yogyakarta, Indonesia. *Procedia Economics and Finance*, 35, 388-395.
- Santoso, I., & Ferdiansyah, F. (2018). Predicting Tourist Arrivals in Bali: A Comparison between Artificial Neural Network and Box-Jenkins Method. *IOP Conference Series: Earth and Environmental Science*, 204, 012015.
- Song, H., & Li, G. (2008). Tourism Demand Modelling and Forecasting – A Review of Recent Research. *Tourism Management*, 29(2), 203-220.
- Nasution, M. Y. (2019). The Relationship between Tourism and Economic Growth: Evidence from ASEAN Countries. *Journal of Economics, Business, and Accountancy Ventura*, 22(3), 659-670.
- Zhang, G. P. (2003). Neural Networks for Classification: A Survey. *IEEE Transactions on Systems, Man, and Cybernetics - Part C: Applications and Reviews*, 30(4), 451-462.
- Santoso, I., & Ferdiansyah, F. (2018). Comparison of Box-Jenkins and Artificial Neural Network Models for Tourist Arrival Forecasting: The Case of Bali, Indonesia. *Journal of Physics: Conference Series*, 978, 012153.