

Model Prediksi Kunjungan Wisata: Mengoptimalkan Arsitektur Algoritma Backpropagation untuk Prediksi Kunjungan Wisata Mancanegara (ASIA)

Mayang Sari^{1*}, Dian Agustini², Muthia Farida³

^{1,2,3}Universitas Islam Kalimantan Muhammad Arsyad Al Banjari Banjarmasin,
Kalimantan Selatan, Indonesia

E-mail: mayangsari.uniska@gmail.com¹, dianagustini.uniska@bjm.ac.id²,
muthiafarida59.uniska@gmail.com³

Abstract

This research focuses on developing a prediction model for tourist visits for foreign destinations in the Asian region using Backpropagation algorithm architecture optimization. Tourism has become a crucial economic sector in Asia, and accurate tourist arrival predictions have a significant impact on decision making in this industry. The main approach used is the Backpropagation algorithm in the context of artificial neural networks. Although these algorithms have been successful in a variety of applications, optimizing Backpropagation architectures for tourism visit prediction remains a significant challenge. This research aims to improve model accuracy and performance by adjusting the Backpropagation algorithm architecture. Through careful optimization, this research seeks to overcome these complex dynamics and produce a model that can provide more accurate estimates of tourist visits. This research presents predictions of foreign tourist visits to Indonesia by optimizing the artificial neural network architecture using the Backpropagation algorithm. Focusing on visit data from various nationalities in the period 2018-2024, the test results highlight the performance variations between architectures in 2023 and 2024. Prediction results show that the 4-3-7-1 architecture obtains high test accuracy in 2023 (88%) , but will decrease in 2024 to 74%. The 4-5-1 architecture showed good consistency with test accuracy remaining high in both years (92%). These findings provide valuable insights for optimal architectural selection in predicting future tourist visits and identifying changing patterns of trends at the national level. However, it should be noted that these results are projective and may be influenced by external factors that may change, requiring ongoing evaluation to ensure model accuracy and responsiveness.

Keywords: Tourist Visit Prediction Model, Backpropagation Algorithm, Artificial Neural Network, Optimization, Asian Tourism.

Abstrak

Penelitian ini fokus pada pengembangan model prediksi kunjungan wisata untuk destinasi mancanegara di kawasan Asia dengan menggunakan optimasi arsitektur algoritma Backpropagation. Pariwisata telah menjadi sektor ekonomi yang krusial di Asia, dan prediksi kunjungan wisata yang akurat memiliki dampak signifikan pada pengambilan keputusan dalam industri ini. Pendekatan utama yang digunakan adalah algoritma Backpropagation dalam konteks jaringan saraf tiruan. Meskipun algoritma ini telah berhasil dalam berbagai aplikasi, pengoptimalkan arsitektur Backpropagation untuk prediksi kunjungan wisata masih merupakan tantangan yang signifikan. Penelitian ini bertujuan untuk meningkatkan akurasi dan kinerja model dengan menyesuaikan arsitektur algoritma Backpropagation. Melalui optimasi yang cermat, penelitian ini berusaha untuk mengatasi dinamika kompleks ini dan menghasilkan model yang dapat memberikan perkiraan kunjungan wisata yang lebih akurat. Penelitian ini menghadirkan prediksi kunjungan wisata mancanegara ke Indonesia dengan mengoptimalkan arsitektur

jaringan saraf tiruan menggunakan algoritma Backpropagation. Berfokus pada data kunjungan dari berbagai kebangsaan dalam periode 2018-2024, hasil pengujian menyoroti variasi performa antar arsitektur pada tahun 2023 dan 2024. Hasil prediksi menunjukkan bahwa arsitektur 4-3-5-1 memperoleh akurasi pengujian yang tinggi yaitu 96%. Arsitektur 4-5-1 menunjukkan konsistensi yang baik dengan akurasi pengujian tetap tinggi pada kedua tahun (92%). Temuan ini memberikan wawasan berharga untuk pemilihan arsitektur yang optimal dalam memprediksi kunjungan wisata masa depan dan mengidentifikasi pola perubahan tren di tingkat nasional.

Kata kunci: Model Prediksi Kunjungan Wisata, Algoritma Backpropagation, Jaringan Saraf Tiruan, Optimasi, Pariwisata Asia.

1. Pendahuluan

Pariwisata telah menjadi sektor ekonomi yang penting bagi banyak negara di dunia, termasuk di kawasan Asia. Perkembangan teknologi informasi dan komunikasi telah memberikan dampak signifikan pada industri pariwisata, dengan semakin banyaknya data yang dihasilkan dari berbagai sumber, seperti reservasi hotel, penerbangan, dan kegiatan wisata lainnya [1], [2]. Oleh karena itu, penting untuk mengembangkan model prediksi kunjungan wisata yang dapat memberikan perkiraan akurat mengenai jumlah wisatawan yang akan mengunjungi suatu destinasi. Prediksi kunjungan wisata menjadi krusial dalam konteks industri pariwisata di kawasan Asia yang terus berkembang. Dalam menghadapi dinamika yang cepat dan kompleks, keberhasilan destinasi pariwisata sangat bergantung pada kemampuan untuk meramalkan jumlah wisatawan dengan akurat [3],[4]. Prediksi yang tepat tidak hanya memungkinkan penyedia layanan pariwisata untuk mengoptimalkan sumber daya dan infrastruktur, tetapi juga memungkinkan pengambil kebijakan dan pemangku kepentingan terkait untuk merancang strategi pemasaran yang efektif, merespons perubahan tren pasar, dan memberikan pengalaman yang memuaskan bagi wisatawan. Dengan memiliki wawasan mendalam mengenai pola kunjungan wisatawan, baik secara musiman maupun jangka panjang, destinasi pariwisata dapat meningkatkan daya saingnya, meningkatkan pendapatan sektor pariwisata, dan secara keseluruhan, mendukung pertumbuhan ekonomi berkelanjutan di kawasan Asia [5], [6].

Sejumlah metode prediksi kunjungan wisata telah dikembangkan untuk mengatasi tantangan kompleks dalam meramalkan perilaku wisatawan. Beberapa metode melibatkan pendekatan statistik tradisional seperti regresi linier dan time series analysis, yang telah lama digunakan untuk memahami hubungan antara variabel-variabel tertentu d[7]–[12]engan kunjungan wisata. Namun, dengan kemajuan teknologi, terutama di bidang kecerdasan buatan, pendekatan berbasis algoritma machine learning dan jaringan saraf tiruan juga menjadi populer [13]. Metode-metode ini mampu menangani pola-pola kompleks dan dinamis dalam data kunjungan wisata, memungkinkan pengidentifikasian hubungan non-linier dan interaksi antar variabel [3], [14]. Selain itu, teknik-teknik seperti ensemble learning dan deep learning memberikan fleksibilitas yang lebih besar dalam menangani dataset besar dan variabel-variabel yang beragam. Penelitian ini akan berfokus pada pengembangan dan optimasi arsitektur algoritma Backpropagation, yang merupakan bagian integral dari jaringan saraf tiruan, dengan harapan memberikan peningkatan signifikan dalam akurasi prediksi kunjungan wisata di kawasan Asia .

Pada penelitian sebelumnya yang dilakukan oleh [15] artikel ini mengusulkan metode baru untuk memprediksi beban listrik jangka panjang dengan menggunakan algoritma optimisasi berbasis pengajaran dan pembelajaran (TLBO) untuk mengoptimalkan jaringan saraf tiruan Feed Forward Backpropagation Neural Network (FFBNN). Metode ini berhasil menghasilkan nilai Mean Absolute Percentage Error (MAPE) yang sangat rendah, menunjukkan efektivitasnya dalam memprediksi beban listrik dengan akurat. Namun kelemahan yang dapat diidentifikasi dalam artikel ini adalah kurangnya

penjelasan yang mendalam tentang parameter dan konfigurasi spesifik dari algoritma Teaching-Learning-Based Optimization (TLBO) yang digunakan untuk mengoptimalkan Feed Forward Backpropagation Neural Network (FFBNN) dalam memprediksi beban listrik jangka panjang.

Sedangkan pada penelitian berikutnya yang dilakukan oleh [16] Artikel ini membahas pengembangan model kecerdasan buatan yang menggunakan jaringan saraf belakang (BPNN) untuk memprediksi keandalan sistem rekayasa. Pendekatan yang diusulkan menawarkan solusi yang lebih akurat dalam memprediksi keandalan sistem rekayasa, dengan potensi aplikasi praktis dalam memprediksi kegagalan sistem dan pengambilan keputusan perawatan tepat waktu. Selain itu, artikel ini memberikan kontribusi dalam pengembangan teknik lanjutan untuk memprediksi keandalan, dengan implikasi potensial untuk berbagai industri, termasuk otomotif, manufaktur, dan robotika. Namun kurangnya akses data tentang keandalan dalam masalah rekayasa lainnya, yang menjadi salah satu batasan utama dari penelitian ini. Oleh karena itu, implementasi BMA-BPNN dalam masalah rekayasa tambahan dan penggunaan algoritma yang diusulkan dalam masalah data berukuran besar dapat menjadi subjek untuk penelitian masa depan.

Dari hasil uji kajian Pustaka dengan pendekatan yang telah banyak digunakan dalam pengembangan model prediksi adalah algoritma Backpropagation, yang merupakan bagian integral dari jaringan saraf tiruan (neural networks). Meskipun algoritma ini telah berhasil di berbagai bidang, namun pengoptimalkan arsitektur algoritma Backpropagation khususnya untuk prediksi kunjungan wisata mancanegara di kawasan Asia masih menjadi tantangan[17]–[19]. Dengan optimasi yang tepat, model prediksi ini dapat memberikan hasil yang lebih akurat dan relevan, membantu pemerintah, perusahaan pariwisata, dan pihak terkait untuk mengambil keputusan yang lebih informasional dan efektif[20].

Selain itu, faktor-faktor yang mempengaruhi kunjungan wisata sangat kompleks dan dinamis, termasuk perubahan tren ekonomi, faktor cuaca, peristiwa global, dan perubahan perilaku konsumen. Oleh karena itu, diperlukan pendekatan yang canggih dan dapat beradaptasi untuk mengatasi kompleksitas ini. Model prediksi yang dioptimalkan dapat membantu mengidentifikasi pola dan tren tersembunyi dalam data, sehingga memberikan wawasan yang lebih mendalam mengenai faktor-faktor yang memengaruhi kunjungan wisata.

Dengan mengoptimalkan arsitektur algoritma Backpropagation, penelitian ini bertujuan untuk meningkatkan akurasi dan kinerja model prediksi kunjungan wisata mancanegara di kawasan Asia. Hal ini diharapkan dapat memberikan kontribusi positif terhadap pengembangan strategi pemasaran, perencanaan infrastruktur pariwisata, dan pengelolaan destinasi wisata di tingkat regional. Dengan demikian, penelitian ini memiliki dampak potensial dalam mendukung pertumbuhan dan keberlanjutan sektor pariwisata di kawasan Asia.

2. Metodologi Penelitian

2.1. Wisata Indonesia

Indonesia, dengan kekayaan alam dan budaya yang melimpah, menawarkan pengalaman wisata yang luar biasa. Destinasi wisata Indonesia mencakup keindahan alam mulai dari pantai-pantai tropis seperti Bali dan Labuan Bajo yang menakjubkan, hingga keberagaman lanskap di Pulau Jawa, Sumatra, dan Kalimantan. Selain itu, situs budaya dan sejarah seperti Candi Borobudur dan Prambanan di Yogyakarta menunjukkan keagungan peradaban masa lalu. Para pengunjung juga dapat mengeksplorasi kekayaan bawah laut Indonesia yang luar biasa dengan menyelam di Taman Nasional Bunaken di Sulawesi atau Raja Ampat di Papua. Makanan yang lezat, keramahan penduduk lokal, dan berbagai tradisi seni membuat Indonesia menjadi destinasi yang mengagumkan bagi para pelancong yang mencari pengalaman yang tak terlupakan [21]–[23].

Indonesia menjadi tujuan utama kunjungan wisata mancanegara bagi wisatawan dari berbagai negara di Asia. Dengan pesona alamnya yang memukau dan keberagaman budayanya, Indonesia menarik perhatian pelancong dari Asia, termasuk negara-negara seperti Singapura, Malaysia, Tiongkok, dan Korea Selatan. Wisatawan dari Asia seringkali tertarik untuk menjelajahi keindahan pulau-pulau tropis seperti Bali, menyaksikan keagungan Candi Borobudur di Yogyakarta, dan menikmati keunikan kehidupan laut di berbagai destinasi menyelam, seperti Raja Ampat di Papua. Selain itu, kuliner Indonesia yang lezat dan keramahan penduduk lokal juga menjadi daya tarik utama bagi wisatawan asal Asia yang ingin merasakan kekayaan dan keanekaragaman Indonesia. Dengan konektivitas yang semakin baik dan layanan pariwisata yang berkembang pesat, kunjungan wisata dari negara-negara Asia ke Indonesia terus menjadi kontributor penting terhadap pertumbuhan industri pariwisata di tanah air[24].

2.2. Dasar Dasar Teori

a. Kecerdasan Buatan

Kecerdasan Buatan atau Intelegensi Artifisial (bahasa Inggris: *Artificial Intelligence* atau hanya disingkat *AI*) didefinisikan sebagai kecerdasan *entitas* ilmiah[25]. Sumbangan terbesar di bidang *AI* diawali oleh tulisan dari Alan Turing pada tahun 1950 berjudul *Computing Machinery and Intelligence* mendiskusikan syarat sebuah mesin dianggap cerdas. Kecerdasan yang dimaksud di sini merujuk pada mesin yang mampu berpikir, menimbang tindakan yang akan diambil dan mampu mengambil keputusan seperti yang dilakukan manusia. Kecerdasan buatan diciptakan dan dimasukkan ke dalam suatu mesin (komputer) agar dapat melakukan pekerjaan seperti yang dapat dilakukan manusia. Beberapa macam bidang yang menggunakan kecerdasan buatan antara lain sistem pakar, permainan komputer (*games*), *logika fuzzy*, Jaringan saraf tiruan dan Robotika [26], [27].

b. Definisi Jaringan saraf tiruan

Jaringan saraf tiruan (JST) (*artificial neural network (ANN) / simulated neural network (SNN) / neural network(NN)*) merupakan jaringan yang terdiri atas sekelompok unit pemroses kecil yang dimodelkan berdasarkan jaringan saraf manusia [25], [28]. JST tercipta sebagai suatu generalisasi model matematis dari pemahaman manusia (*human cognition*) yang didasarkan atas asumsi pemrosesan informasi terjadi pada elemen sederhana yang disebut *neuron*, sinyal mengalir diantara sel saraf/*neuron* melalui suatu sambungan penghubung, setiap sambungan penghubung memiliki bobot yang bersesuaian [29]. Bobot ini untuk menggandakan/ mengalihkan sinyal yang dikirim, setiap sel saraf akan menerapkan fungsi aktivasi terhadap sinyal hasil penjumlahan berbobot yang masuk kepadanya untuk menentukan sinyal keluarannya[27].

2.3. Model Jaringan *Backpropagation*

Model jaringan *Backpropagation* merupakan suatu teknik pembelajaran atau pelatihan *supervised learning* yang paling banyak digunakan. Algoritma ini merupakan salah satu algoritma yang sangat baik dalam menangani masalah pengenalan pola-pola kompleks[30], [29]. Didalam jaringan *Backpropagation*, setiap unit yang berada di lapisan *input* berhubungan dengan setiap unit yang ada di lapisan tersembunyi. Setiap unit yang ada di lapisan tersembunyi terhubung dengan setiap unit yang ada di lapisan *output*. Jaringan ini terdiri dari banyak lapisan (*multilayer network*). Ketika jaringan ini diberikan pola masukan sebagai pola pelatihan, maka pola tersebut menuju unit-unit lapisan tersembunyi untuk selanjutnya diteruskan pada unit-unit dilapisan keluaran. Kemudian unit-unit lapisan keluaran akan memberikan respon sebagai keluaran jaringan saraf tiruan. Saat hasil keluaran tidak sesuai dengan yang diharapkan, maka keluaran akan disebarkan mundur (*backward*) pada lapisan tersembunyi kemudian dari lapisan tersembunyi menuju lapisan masukan [31].


Tahap pelatihan ini merupakan langkah untuk melatih suatu jaringan saraf tiruan, yaitu dengan cara melakukan perubahan bobot, sedangkan penyelesaian masalah akan dilakukan jika proses pelatihan tersebut telah selesai, fase ini disebut fase pengujian.

$$x^1 = \frac{0.8(x-a)}{b-a} + 0.1 \quad (1)$$

2.3.1. Arsitektur Jaringan Backpropagation

Setiap unit dari *layer input* pada jaringan *Backpropagation* selalu terhubung dengan setiap unit yang berada pada *layer* tersembunyi, demikian juga setiap unit *layer* tersembunyi selalu terhubung dengan unit pada *layer output* [27]. Jaringan *Backpropagation* terdiri dari banyak lapisan (*multilayer network*) yaitu:

- Lapisan *input* (1 buah), yang terdiri dari 1 hingga n unit *input*.
- Lapisan tersembunyi (minimal 1 buah), yang terdiri dari 1 hingga p unit tersembunyi.
- Lapisan *output* (1 buah), yang terdiri dari 1 hingga m unit *output*.



Gambar 1. Arsitektur Jaringan *Backpropagation*

2.3.2. Pelatihan Jaringan Backpropagation

Aturan pelatihan jaringan *Backpropagation* terdiri dari 2 tahapan, *feedforward* dan *backward propagation*. Pada jaringan diberikan sekumpulan contoh pelatihan yang disebut set pelatihan. Set pelatihan ini digambarkan dengan sebuah vektor *feature* yang disebut dengan vektor *input* yang diasosiasikan dengan sebuah *output* yang menjadi target pelatihannya. Dengan kata lain set pelatihan terdiri dari vektor *input* dan juga vektor *output* target. Keluaran dari jaringan berupa sebuah vektor *output* aktual. Selanjutnya dilakukan perbandingan antara *output* aktual yang dihasilkan dengan *output* target dengan cara melakukan pengurangan diantara kedua *output* tersebut. Hasil dari pengurangan berupa *Error*. *Error* dijadikan sebagai dasar dalam melakukan perubahan dari setiap bobot dengan mempropagasi kembali [30].

Setiap perubahan bobot yang terjadi dapat mengurangi *Error*. Siklus perubahan bobot (*epoch*) dilakukan pada setiap set pelatihan sehingga kondisi berhenti dicapai, yaitu bila mencapai jumlah *epoch* yang diinginkan atau hingga sebuah nilai ambang yang ditetapkan terlampaui [32], [29]. Algoritma pelatihan jaringan *Backpropagation* terdiri dari 3 tahapan yaitu:

- Tahap umpan maju (*feedforward*).
- Tahap umpan mundur (*Backpropagation*).
- Tahap pengupdatean bobot dan bias [31]

2.3.3. Pengujian Jaringan Backpropagation

Setelah bobot yang terbaik pada tahap pelatihan didapat, maka nilai pembobot tersebut digunakan untuk mengolah data masukan untuk menghasilkan keluaran yang sesuai. Hal ini digunakan untuk menguji apakah JST dapat bekerja dengan baik yaitu dapat memprediksi pola data yang telah dilatihkan dengan tingkat kesalahan yang kecil[30].

2.4. Konvergensi

Konvergensi merupakan nilai data yang akan semakin mengecil, dimana jaringan akan pada kondisi stabil di nilai minimum. Dapat dibuktikan pada tiap unit pengolahan nilai akan selalu berkurang atau tetap, sebagai hasilnya unit pengolahan nilai berada pada nilai minimum untuk konvergen.

2.5. Ukuran Ketepatan

Ukuran Ketepatan yang sering digunakan untuk mengetahui ketepatan suatu metode yaitu sebagai berikut

- a. Nilai Tengah Galat (Mean Squared Error)


$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \text{ dimana } e_i = X_i - F_i \quad (2)$$

- b. Jumlah Kuadrat Galat (Sum of Squard Error)

$$SSE = \sum_{i=1}^n e_i^2 \text{ dimana } e_i = X_i - F_i \quad (3)$$

2.6. Rancangan Penelitian

Rancangan atau model penelitian disajikan dalam rancangan *Flowchart* Gambar 1.



Gambar 2. Rancangan Penelitian


Pada Gambar 2 dapat dijelaskan bahwa hal pertama yang dilakukan pada pengusulan makalah ini adalah menyiapkan dataset, yakni data Indeks Pembangunan Manusia di Indonesia. Selanjutnya dataset tersebut dibagi menjadi 2 bagian, untuk data training (training) dan data testing (Testing). Langkah berikutnya melakukan normalisasi terhadap data training dan data testing. Setelah data dinormalisasi, selanjutnya memilih atau menentukan model arsitektur jaringan yang akan digunakan untuk proses training dan Testing dengan menggunakan aplikasi Matlab 2016a dan Microsoft Excel. Proses training dan Testing dilakukan dengan menggunakan parameter gradient descent (traingd, traingdm, traingda, dan traingdx) dan fungsi aktivasi/fungsi transfer (tansig, purelin, logsig). Matlab akan memberikan hasil perhitungan (output) dari data yang sudah di masukkan dan diproses pada training dan testing dengan menggunakan model arsitektur yang sudah ditentukan secara random. Hasil output dari Matlab ini nantinya akan

dimasukkan kedalam Microsoft Excel untuk diolah dan dihitung kembali serta dianalisa sampai memperoleh model arsitektur yang terbaik. Model arsitektur yang terbaik ditentukan berdasarkan perbandingan beberapa model arsitektur yang sudah ditentukan secara random.

Penelitian ini menggunakan pendekatan gabungan antara analisis data historis kunjungan wisata dari negara-negara Asia ke Indonesia dengan pengembangan model prediksi menggunakan algoritma Backpropagation dalam konteks jaringan saraf tiruan (neural networks). Data kunjungan wisata yang diperoleh melibatkan serangkaian variabel, termasuk musim, kondisi ekonomi, peristiwa global, dan faktor-faktor lain yang dapat memengaruhi pola kunjungan. Langkah pertama melibatkan pre-processing data, termasuk normalisasi dan pemilihan fitur yang relevan. Selanjutnya, dilakukan pelatihan model menggunakan algoritma Backpropagation dengan variasi arsitektur jaringan untuk mengoptimalkan performa prediksi. Pengujian dan validasi model dilakukan dengan menggunakan data yang tidak terlibat dalam pelatihan untuk mengevaluasi akurasi dan keandalan prediksi.

2.7. Metode Penelitian

Proses penelitian ini bertujuan untuk mengidentifikasi arsitektur optimal untuk algoritma Backpropagation dalam konteks prediksi kunjungan wisata mancanegara dari negara-negara Asia ke Indonesia. Metodologi ini diharapkan memberikan kontribusi pada peningkatan akurasi dan ketepatan model prediksi kunjungan wisata, mendukung pengambilan keputusan yang lebih efektif di bidang pariwisata. Berikut flowchart penelitian yang digunakan oleh peneliti. Rancangan atau model penelitian disajikan dalam rancangan *Flowchart* pada Gambar 3:



Gambar 3. Rancangan Penelitian

Pada Gambar 3 dapat dijelaskan bahwa hal pertama yang dilakukan pada pengusulan makalah ini adalah menyiapkan dataset, yakni data Indeks Pembangunan Manusia di Indonesia. Selanjutnya dataset tersebut dibagi menjadi 2 bagian, untuk data training (training) dan data testing (Testing). Langkah berikutnya melakukan normalisasi terhadap data training dan data testing. Setelah data dinormalisasi, selanjutnya memilih atau menentukan model arsitektur jaringan yang akan digunakan untuk proses training dan Testing dengan menggunakan aplikasi Matlab 2016a dan Microsoft Excel. Pengembangan Model dengan Inisialisasi model jaringan saraf tiruan dengan algoritma Backpropagation, kemudian tentukan arsitektur awal jaringan setelah itu melakukan pelatihan model menggunakan data historis dan variasikan arsitektur jaringan untuk mencari konfigurasi optimal. Evaluasi Model dengan menggunakan data yang tidak terlibat dalam pelatihan untuk pengujian dan validasi model dan hitung metrik evaluasi seperti akurasi prediksi.

Bandingkan hasil dengan metode prediksi lainnya (regresi linier, time series analysis). Proses training dan Testing dilakukan dengan menggunakan parameter gradient descent (traingd, traingdm, traingda, dan traingdx) dan fungsi aktivasi/fungsi transfer (tansig, purelin, logsig). Matlab akan memberikan hasil perhitungan (output) dari data yang sudah di masukkan dan diproses pada training dan testing dengan menggunakan model arsitektur yang sudah ditentukan secara random. Hasil output dari Matlab ini nantinya akan dimasukkan kedalam Microsoft Excel untuk diolah dan dihitung kembali serta dianalisa sampai memperoleh model arsitektur yang terbaik. Model arsitektur yang terbaik ditentukan berdasarkan perbandingan beberapa model arsitektur yang sudah ditentukan secara random.

3. Hasil Dan Pembahasan

3.1. Hasil

Objek penelitian ini, yakni pengembangan model prediksi kunjungan wisata dengan mengoptimalkan arsitektur algoritma Backpropagation, menandai langkah signifikan dalam memperkuat kapabilitas prediksi di sektor pariwisata Indonesia. Fokus pada kunjungan wisata dari negara-negara Asia memberikan pemahaman mendalam tentang pola dan dinamika yang memengaruhi keputusan perjalanan wisatawan. Melalui pendekatan berbasis jaringan saraf tiruan dan pengoptimalan algoritma Backpropagation, penelitian ini tidak hanya menjawab tantangan kompleksitas data yang berkaitan dengan kunjungan wisata, tetapi juga mengeksplorasi potensi teknologi kecerdasan buatan dalam memberikan hasil prediksi yang lebih akurat. Objek penelitian ini bukan hanya menyediakan kerangka kerja analisis yang kuat bagi pihak-pihak terkait dalam industri pariwisata, tetapi juga memberikan landasan untuk pengembangan strategi pemasaran yang lebih terfokus dan kebijakan yang lebih responsif terhadap tren wisata global dan regional. Berikut merupakan dataset yang digunakan untuk pengujian yang diambil dari BPS.

Tabel 1. Data Set Penelitian Kunjungan Wisatawan Mancanegara

No	Kebangsaan	Jumlah Kunjungan Wisatawan Mancanegara ke Indonesia Menurut Kebangsaan (Kunjungan)					
		2017	2018	2019	2020	2021	2022
1	Brunei Darussalam	23455	17279	19278	2701	144	6624
2	Malaysia	2121888	2503344	2980753	980118	480723	452739
3	Filipina	308977	217874	260980	50413	9375	62274
4	Singapura	1554119	1768744	1934445	280492	18704	1290186
5	Thailand	138235	124153	136699	21303	3992	66484
6	Vietnam	77466	75816	96024	19608	2008	41736
7	Myanmar	48133	28612	46381	12669	3093	183
9	Hong Kong	98272	91182	50324	2625	2432	23003
10	India	536902	595636	657300	111724	6670	380739
11	Jepang	573310	530573	519623	92228	5952	209698
12	Korea Selatan	423191	358885	388316	75562	9497	127470
13	Pakistan	11424	13448	14663	4110	974	2987
14	Bangladesh	56503	56564	59777	12866	1001	21191
15	Sri Lanka	35669	32508	28907	4300	620	11599
16	Taiwan	264278	208317	207490	35680	1398	61767
17	Tionghoa	2093171	2139161	2072079	239768	54713	1359974
18	Timor Leste	960026	1762422	1178381	994590	819488	1466238
19	Saudi Arabia	182086	165912	157512	31906	2053	47111
20	Bahrain	2457	2324	2631	373	35	426
21	Kuwait	5760	5551	5762	846	75	2055
22	Mesir	20345	18075	21354	4337	611	6823
23	Uni Emirat Arab	8387	7100	9065	1093	384	4483
24	Yaman	8453	10008	9221	2094	758	2613
25	Qatar	1859	2104	1989	225	43	339

3.1.1. Implementasi Pemrosesan Algoritma Backpropagation Menggunakan Tools Matlab R2016a

a) Proses Normalisasi

Proses normalisasi merupakan suatu langkah kerja dalam memindahkan angka dari kolom menjadi baris dan dari bilangan bulat menjadi pecahan, hal ini dilakukan agar data tadi mudah untuk dilakukan proses perkalian bobot pada matlab karna memiliki angka pecahan atau dinormalisasikan. Untuk mentransformasikan seluruh data real tersebut, digunakan fungsi rumus sebagai berikut.:

$$x^1 = \frac{0.8(23455-35)}{2980753-35} + 0.1 = 0,1063$$

b) Proses Normalisasi Data Kunjungan Wisatawan

Sebelum proses pengolahan data dilakukan, perlu dilakukan proses penentuan masukan (*Input*) serta target atau hasil yang diinginkan dari proses pengolahan data, berikut data *Input* dan target berdasarkan data kunjungan wisatawan yang telah dikumpulkan, sampel yang diambil adalah 1 sampel :

c) Data Pelatihan dan Pengujian

Setelah data *Input* dan target di tentukan, maka langkah selanjutnya adalah menentukan data pelatihan dan pengujian, berikut data pelatihan dan pengujian :

Tabel 2. Data Pelatihan


X1 (2017)	X2 (2018)	X3 (2019)	X4 (2020)	T(2021)
0,1063	0,1046	0,1052	0,1007	0,1000
0,6695	0,7719	0,9000	0,3630	0,2290
0,1829	0,1585	0,1700	0,1135	0,1025
0,5171	0,5747	0,6192	0,1753	0,1050
0,1371	0,1333	0,1367	0,1057	0,1011
0,1208	0,1203	0,1258	0,1053	0,1005
0,1129	0,1077	0,1124	0,1034	0,1008
0,1264	0,1245	0,1135	0,1007	0,1006
0,2441	0,2599	0,2764	0,1300	0,1018
0,2539	0,2424	0,2395	0,1247	0,1016
0,2136	0,1963	0,2042	0,1203	0,1025
0,1031	0,1036	0,1039	0,1011	0,1003
0,1152	0,1152	0,1160	0,1034	0,1003
0,1096	0,1087	0,1077	0,1011	0,1002
0,1709	0,1559	0,1557	0,1096	0,1004
0,6618	0,6741	0,6561	0,1643	0,1147
0,3577	0,5730	0,4163	0,3669	0,3199
0,1489	0,1445	0,1423	0,1086	0,1005
0,1007	0,1006	0,1007	0,1001	0,1000
0,1015	0,1015	0,1015	0,1002	0,1000
0,1055	0,1048	0,1057	0,1012	0,1002
0,1022	0,1019	0,1024	0,1003	0,1001
0,1023	0,1027	0,1025	0,1006	0,1002
0,1005	0,1006	0,1005	0,1001	0,1000

Tabel 3. Data Pengujian

X1 (2018)	X2 (2019)	X3 (2020)	X4 (2021)	T (2022)
0,1046	0,1052	0,1007	0,1000	0,1018
0,7719	0,9000	0,3630	0,2290	0,2215
0,1585	0,1700	0,1135	0,1025	0,1167
0,5747	0,6192	0,1753	0,1050	0,4463
0,1333	0,1367	0,1057	0,1011	0,1178
0,1203	0,1258	0,1053	0,1005	0,1112
0,1077	0,1124	0,1034	0,1008	0,1000
0,1245	0,1135	0,1007	0,1006	0,1062
0,2599	0,2764	0,1300	0,1018	0,2022
0,2424	0,2395	0,1247	0,1016	0,1563
0,1963	0,2042	0,1203	0,1025	0,1342
0,1036	0,1039	0,1011	0,1003	0,1008
0,1152	0,1160	0,1034	0,1003	0,1057
0,1087	0,1077	0,1011	0,1002	0,1031
0,1559	0,1557	0,1096	0,1004	0,1166
0,6741	0,6561	0,1643	0,1147	0,4650
0,5730	0,4163	0,3669	0,3199	0,4935
0,1445	0,1423	0,1086	0,1005	0,1126
0,1006	0,1007	0,1001	0,1000	0,1001
0,1015	0,1015	0,1002	0,1000	0,1005
0,1048	0,1057	0,1012	0,1002	0,1018
0,1019	0,1024	0,1003	0,1001	0,1012
0,1027	0,1025	0,1006	0,1002	0,1007
0,1006	0,1005	0,1001	0,1000	0,1001

d) Perancangan Manual Jaringan saraf tiruan

Tahap berikutnya yaitu merancang arsitektur JST backpropagation. Dalam hal ini menggunakan beberapa model jaringan multi-layer (banyak lapisan) yang digunakan untuk mendapatkan arsitektur terbaik adalah 4-2-1, 4-5-1, 4-7-1, 4-3-5-1 dan 4-3-7-1. Model sampel arsitektur4-2-1 dapat dilihat pada Gambar dibawah ini.



Gambar 4. Arsitektur Jaringan *Backpropagation*

Gambar 4. Merupakan sampel yang ditampilkan penulis dalam artikel ini yang arsitektur ini merupakan salah satu arsitektur yang digunakan dalam pengujian model prediksi kunjungan wisatawan mancanegara khususnya ASIA yang masuk ke Indonesia.

3.1.2. Pelatihan dan Pengujian dengan Software Matlab R2016a


Matlab (*matrix laboratory*) merupakan salah satu perangkat lunak yang dirancang khusus sebagai solusi untuk mengerjakan permasalahan yang berkaitan dengan matematika. Berikut merupakan sampel model arsitektur terbaik yang ditampilkan pada pengujian model prediksi wisata berikut ini.

3.1.3. Pelatihan dan Pengujian Arsitektur 4-3-5-1

Berikut adalah hasil pelatihan dan pengujian dengan 24 data untuk arsitektur 4-3-5-1. Adapun parameter yang digunakan.


Koding Pelatihan	Koding Pengujian
<pre>>> net=newff(minmax(P),[3,5,1],{'logsig','tansig','logsig'},'trainingd'); >> net.IW{1,1}; >> net.b{1}; >> net.LW{2,1}; >> net.trainParam.epochs=100000; >> net.trainParam.goal = 0.01; >> net.trainParam.Lr = 0.01; >> net.trainParam.show = 1000; >> net=train(net,P,T) [a,Pf,Af,e,Perf]=sim(net,P,[],[],T)</pre>	<pre>>> PP= >> TT= >> [a,Pf,Af,e,Perf]=sim(net,PP,[],[],TT)</pre>

Setelah dilakukan perulangan maka ditemukan *error minimum* pada *epoch* 49 Seperti pada Gambar 5.



Gambar 5. Pelatihan Arsitektur 4-3-5-1

Pada Gambar 5. Dapat bisa dilihat bahwa epoch, time, performance serta gradient dan validation dapat dilihat pada tampilan yang dihasilkan dari tools matlab saat pengolahan model dilakukan.



Gambar 6. Grafik Performance pelatihan arsitektur 4-3-5-1

Untuk Gambar 6, menampilkan grafik performance pelatihan yang membantuk kurva yang sangat baik karena begitu cepat membantuk lekukan untuk mendapatkan Goal yang diinginkan. Untuk hasil yang lebih rinci dan mengetahui *output* dan *error* dapat dilihat pada Tabel 4 dan 5.

Tabel 4. Hasil Pelatihan dengan Model
4-3-5-1

No	Target	Output JST	Error	SSE	Hasil
1	0,1000	0,0962	0,0038	0,0000	1
2	0,2290	-0,0218	0,2508	0,0629	0
3	0,1025	0,1498	-0,0473	0,0022	1
4	0,1050	0,3316	-0,2266	0,0513	1
5	0,1011	0,1195	-0,0184	0,0003	1
6	0,1005	0,1051	-0,0046	0,0000	1
7	0,1008	0,0985	0,0023	0,0000	1
8	0,1006	0,1149	-0,0143	0,0002	1
9	0,1018	0,2092	-0,1074	0,0115	1
10	0,1016	0,2198	-0,1182	0,0140	1
11	0,1025	0,1748	-0,0723	0,0052	1
12	0,1003	0,0931	0,0072	0,0001	1
13	0,1003	0,1019	-0,0016	0,0000	1
14	0,1002	0,0990	0,0012	0,0000	1
15	0,1004	0,1444	-0,0441	0,0019	1
16	0,1147	0,2548	-0,1402	0,0196	1
17	0,3199	0,0576	0,2623	0,0688	0
18	0,1005	0,1267	-0,0262	0,0007	1
19	0,1000	0,0919	0,0081	0,0001	1
20	0,1000	0,0925	0,0075	0,0001	1
21	0,1002	0,0950	0,0051	0,0000	1
22	0,1001	0,0930	0,0071	0,0000	1
23	0,1002	0,0929	0,0073	0,0001	1
24	0,1000	0,0917	0,0083	0,0001	1
				0,23925	92
				MSE 0,01993724	

Tabel 5. Hasil Pengujian dengan Model
4-3-5-1

No	Target	Output JST	Error	SSE	Hasil
1	0,10177	0,1062	-0,0045	0,0000	1
2	0,22150	0,5228	-0,3013	0,0908	1
3	0,11670	0,1903	-0,0736	0,0054	1
4	0,44627	0,5260	-0,0798	0,0064	1
5	0,11783	0,1419	-0,0241	0,0006	1
6	0,11119	0,1259	-0,0147	0,0002	1
7	0,10004	0,1100	-0,0100	0,0001	1
8	0,10616	0,1244	-0,0182	0,0003	1
9	0,20218	0,4130	-0,2109	0,0445	1
10	0,15627	0,3734	-0,2171	0,0471	1
11	0,13420	0,2755	-0,1413	0,0200	1
12	0,10079	0,1051	-0,0043	0,0000	1
13	0,10568	0,1182	-0,0125	0,0002	1
14	0,10310	0,1098	-0,0067	0,0000	1
15	0,11657	0,1839	-0,0673	0,0045	1
16	0,46500	0,5273	-0,0623	0,0039	1
17	0,49352	0,3809	0,1126	0,0127	0
18	0,11263	0,1616	-0,0489	0,0024	1
19	0,10010	0,1024	-0,0023	0,0000	1
20	0,10054	0,1032	-0,0026	0,0000	1
21	0,10182	0,1064	-0,0046	0,0000	1
22	0,10119	0,1035	-0,0023	0,0000	1
23	0,10069	0,1041	-0,0034	0,0000	1
24	0,10008	0,1024	-0,0023	0,0000	1
				0,23914	96
				MSE 0,01992799	

Matlab (*matrix laboratory*) merupakan salah satu perangkat lunak yang dirancang khusus sebagai solusi untuk mengerjakan permasalahan yang berkaitan dengan matematika.

3.2. Pembahasan

Pembahasan hasil menyoroti signifikansinya dalam mendukung pengambilan keputusan di sektor pariwisata. Model yang dihasilkan dapat memberikan wawasan yang lebih mendalam tentang pola kunjungan, memungkinkan pemerintah, perusahaan pariwisata, dan pemangku kepentingan terkait untuk mengambil tindakan yang lebih proaktif dan efisien. Selain itu, keunggulan model dalam memprediksi tren kunjungan wisata dapat menjadi dasar strategi pemasaran yang lebih tepat sasaran dan berdampak

positif terhadap pertumbuhan industri pariwisata di Indonesia. Namun, perlu diakui bahwa model ini juga harus terus diperbarui dan disesuaikan dengan perubahan kondisi dan faktor-faktor lingkungan yang dapat memengaruhi dinamika kunjungan wisata.

Tabel 6. Hasil Pengolahan Model Optimasi Arsitektur Backpropagation

Arsitektur	Training			Testing	
	Epoch	MSE	Akurasi	MSE	Akurasi
4-2-1	34	0,0188487	42%	0,0198862	88%
4-5-1	53	0,0197668	92%	0,0198238	92%
4-7-1	56	0,0192881	96%	0,0189969	88%
4-3-5-1	49	0,0199372	92%	0,0199280	96%
4-3-7-1	18	0,0178216	74%	0,0167558	88%

Tabel tersebut memberikan hasil pelatihan (training) dan pengujian (testing) dari beberapa arsitektur model jaringan saraf tiruan dengan algoritma Backpropagation untuk prediksi kunjungan wisata. Setiap baris merepresentasikan satu arsitektur dengan format "jumlah input - jumlah hidden layer - jumlah output".

Dengan menganalisis tabel ini, peneliti dapat memilih arsitektur model yang paling sesuai dengan tujuan penelitian berdasarkan performa pada data latih dan data uji. Model dengan keseimbangan yang baik antara akurasi pada data latih dan data uji akan menjadi pilihan yang diinginkan untuk aplikasi praktis dalam prediksi kunjungan wisata.

Dari hasil pengelolaan yang tercatat dalam tabel, dapat dilihat bahwa berbagai arsitektur jaringan saraf tiruan telah menghasilkan tingkat akurasi yang beragam pada fase pelatihan dan pengujian. Arsitektur 4-7-1 menonjol dengan akurasi tertinggi pada fase pelatihan sebesar 96%, namun, mengalami penurunan pada fase pengujian menjadi 88%. Di sisi lain, arsitektur 4-5-1 menunjukkan konsistensi tinggi antara fase pelatihan dan pengujian dengan akurasi mencapai 92%. Meskipun arsitektur 4-3-7-1 mengalami penurunan kecil pada akurasi pengujian (88%), namun menunjukkan kemampuan yang baik dalam menggeneralisasi pada data yang belum pernah terlihat sebelumnya. Dari hasil arsitektur 4-3-5-1 merupakan hasil arsitektur terbaik dengan adanya akurasi yang baik pada pelatihan dan terjadi peningkatan saat pengujian. Hasil ini mengindikasikan bahwa arsitektur 4-3-5-1 mungkin menjadi pilihan yang solid untuk model prediksi kunjungan wisata dari negara-negara Asia ke Indonesia dalam konteks penelitian ini, karena mampu memberikan keseimbangan yang baik antara akurasi pelatihan dan pengujian serta kinerja yang memadai dalam menghadapi variasi data.

Setelah didapatkan arsitektur terbaik dari pelatihan dan pengujian data, selanjutnya akan dilakukan prediksi untuk beberapa tahun yang akan datang. Menggunakan data pengujian dalam melakukan prediksi dan arsitektur terbaik. Prediksi menggunakan arsitektur terbaik 4-3-5-1. Maksudnya, layer masukan menggunakan 3 neuron layer masukan, ada 2 hidden layer tersembunyi yaitu layer tersembunyi pertama 3 neuron, layer tersembunyi kedua 5 neuron, serta 1 neuron layer keluaran. Pada Tabel 7 Prediksi ditentukan menggunakan persamaan sebagai prediksi = $(output - 0,1) (b - a) / 0,8 + a$. Proses prediksi dapat dilihat pada tabel 6 berikut:

Tabel 7. Hasil Pegelolahan Prediksi dengan Arsitektur 4-3-5-1

Daerah	Prediksi Tahun 2023				Prediksi Tahun 2024			
	Data Real	Target	Target Prediksi	Hasil Prediksi	Data Real	Target	Target Prediksi	Hasil Prediksi
Brunei Darussalam	6624	0,1018	0,0761	60074	60074	0,0761	0,155079	205244
Malaysia	452739	0,2215	0,1235	236442	236442	0,1235	0,365222	988215
Filipina	62274	0,1167	0,1390	294291	294291	0,1390	0,248549	553502
Singapura	1290186	0,4463	0,5722	1908308	1908308	0,5722	0,361511	974387
Thailand	66484	0,1178	0,1076	177397	177397	0,1076	0,175565	281573
Vietnam	41736	0,1112	0,0947	129265	129265	0,0947	0,171406	266076
Myanmar	183	0,1000	0,0794	72476	72476	0,0794	0,172168	268913
Hong Kong	23003	0,1062	0,0939	126213	126213	0,0939	0,159069	220107
India	380739	0,2022	0,3262	991858	991858	0,3262	0,255107	577937
Jepang	209698	0,1563	0,2767	807262	807262	0,2767	0,298995	741460
Korea Selatan	127470	0,1342	0,1927	494376	494376	0,1927	0,281725	677111

Daerah	Prediksi Tahun 2023				Prediksi Tahun 2024			
	Data Real	Target	Target Prediksi	Hasil Prediksi	Data Real	Target	Target Prediksi	Hasil Prediksi
Pakistan	2987	0,1008	0,0745	53877	53877	0,0745	0,155872	208197
Bangladesh	21191	0,1057	0,0878	103717	103717	0,0878	0,165671	244706
Sri Lanka	11599	0,1031	0,0799	74005	74005	0,0799	0,15671	211320
Taiwan	61767	0,1166	0,1366	285542	285542	0,1366	0,212899	420675
Tionghoa	1359974	0,4650	0,4989	1635281	1635281	0,4989	0,374421	1022488
Timor Leste	1466238	0,4935	0,7358	2518088	2518088	0,7358	0,526445	1588915
Saudi Arabia	47111	0,1126	0,1217	230041	230041	0,1217	0,1982	365906
Bahrain	426	0,1001	0,0716	43098	43098	0,0716	0,151649	192463
Kuwait	2055	0,1005	0,0725	46692	46692	0,0725	0,15208	194067
Mesir	6823	0,1018	0,0761	60072	60072	0,0761	0,156451	210354
Uni Emirat Arab	4483	0,1012	0,0729	47993	47993	0,0729	0,152253	194714
Yaman	2613	0,1007	0,0734	50130	50130	0,0734	0,153633	199856
Qatar	339	0,1001	0,0715	42936	42936	0,0715	0,151392	191506

Tabel 8. Hasil Prediksi

No	Kebangsaan	Tahun						
		2018	2019	2020	2021	2022	2023	2024
1	Brunei Darussalam	17279	19278	2701	144	6624	60074	205244
2	Malaysia	2503344	2980753	980118	480723	452739	236442	988215
3	Filipina	217874	260980	50413	9375	62274	294291	553502
4	Singapura	1768744	1934445	280492	18704	1290186	1908308	974387
5	Thailand	124153	136699	21303	3992	66484	177397	281573
6	Vietnam	75816	96024	19608	2008	41736	129265	266076
7	Myanmar	28612	46381	12669	3093	183	72476	268913
9	Hong Kong	91182	50324	2625	2432	23003	126213	220107
10	India	595636	657300	111724	6670	380739	991858	577937
11	Jepang	530573	519623	92228	5952	209698	807262	741460
12	Korea Selatan	358885	388316	75562	9497	127470	494376	677111
13	Pakistan	13448	14663	4110	974	2987	53877	208197
14	Bangladesh	56564	59777	12866	1001	21191	103717	244706
15	Sri Lanka	32508	28907	4300	620	11599	74005	211320
16	Taiwan	208317	207490	35680	1398	61767	285542	420675
17	Tionghoa	2139161	2072079	239768	54713	1359974	1635281	1022488
18	Timor Leste	1762422	1178381	994590	819488	1466238	2518088	1588915
19	Saudi Arabia	165912	157512	31906	2053	47111	230041	365906
20	Bahrain	2324	2631	373	35	426	43098	192463
21	Kuwait	5551	5762	846	75	2055	46692	194067
22	Mesir	18075	21354	4337	611	6823	60072	210354
23	Uni Emirat Arab	7100	9065	1093	384	4483	47993	194714
24	Yaman	10008	9221	2094	758	2613	50130	199856
25	Qatar	2104	1989	225	43	339	42936	191506

Pada Tabel 8. hasil prediksi kunjungan wisata ke Indonesia pada tahun 2023 dan 2024, berdasarkan model jaringan saraf tiruan, menunjukkan variasi yang signifikan antara berbagai kebangsaan. Peningkatan jumlah kunjungan diprediksi dari beberapa negara, seperti Malaysia, Filipina, dan Vietnam, yang menunjukkan pertumbuhan yang konsisten. Sebaliknya, negara-negara seperti Brunei Darussalam dan India mengalami lonjakan yang sangat besar pada tahun 2024. Sementara itu, beberapa negara seperti Singapura dan Jepang menunjukkan tren stabil pada tahun 2023, tetapi mengalami penurunan pada tahun 2024. Timor Leste memproyeksikan pertumbuhan eksplosif dalam kunjungan wisata, sedangkan China dan Saudi Arabia menunjukkan tren yang relatif stabil. Meskipun hasil ini memberikan Gambaran perkiraan kunjungan wisata, perlu diingat bahwa proyeksi ini dapat dipengaruhi oleh berbagai faktor eksternal yang dapat berubah seiring waktu.

4. Kesimpulan

Berdasarkan hasil eksperimen yang tercatat dalam tabel, dapat disimpulkan bahwa arsitektur jaringan saraf tiruan yang menunjukkan performa terbaik pada data uji (testing) adalah arsitektur 4-3-5-1, dengan akurasi sebesar 96%. Meskipun terdapat variasi dalam jumlah epoch dan Mean Squared Error (MSE) pada data training dan testing, arsitektur 4-

3-5-1 menonjol dengan tingkat akurasi yang konsisten tinggi pada fase pengujian. Oleh karena itu, arsitektur 4-3-5-1 dapat dianggap sebagai pilihan terbaik untuk model prediksi kunjungan wisata dalam konteks penelitian ini, karena mampu memberikan hasil yang baik pada data yang tidak pernah terlibat dalam proses pelatihan. Kesimpulan ini memberikan panduan untuk pengembangan model yang lebih akurat dan responsif terhadap variasi dinamika kunjungan wisata dari negara-negara Asia ke Indonesia.

Daftar Pustaka

- [1] W. Tang, "Determination of monophenolase activity based on backpropagation neural network analysis of three-dimensional fluorescence spectroscopy," *J. Biotechnol.*, vol. 365, pp. 11–19, 2023, doi: 10.1016/j.jbiotec.2023.02.001.
- [2] P. Alkhairi, I. S. Damanik, and A. P. Windarto, "Penerapan Jaringan Saraf Tiruan untuk Mengukur Korelasi Beban Kerja Dosen Terhadap Peningkatan Jumlah Publikasi," *Pros. Semin. Nas. Ris. Inf. Sci.*, vol. 1, no. September, p. 581, 2019, doi: 10.30645/senaris.v1i0.65.
- [3] J. Gould, "Backpropagation Computation for Training Graph Attention Networks," *J. Signal Process. Syst.*, 2023, doi: 10.1007/s11265-023-01897-1.
- [4] B. H. H. Putrama Alkhairi, "Penerapan algoritma backpropagation untuk mengenali pola tulisan angka dengan fungsi pelatihan gradient descent with momentum adaptive lr 1,2," vol. 1, no. 3, pp. 126–139, 2022.
- [5] P. Alkhairi, E. R. Batubara, R. Rosnelly, W. Wanayaumini, and H. S. Tambunan, "Effect of Gradient Descent With Momentum Backpropagation Training Function in Detecting Alphabet Letters," *Sinkron*, vol. 8, no. 1, pp. 574–583, 2023, doi: 10.33395/sinkron.v8i1.12183.
- [6] A. Wanto *et al.*, "Analysis of the Accuracy Batch Training Method in Viewing Indonesian Fisheries Cultivation Company Development," *J. Phys. Conf. Ser.*, vol. 1255, no. 1, 2019, doi: 10.1088/1742-6596/1255/1/012003.
- [7] S. M. Al Sasongko, "Application of Gray Scale Matrix Technique for Identification of Lombok Songket Patterns Based on Backpropagation Learning," *Int. J. Informatics Vis.*, vol. 6, no. 4, pp. 835–841, 2022, doi: 10.30630/joiv.6.4.1532.
- [8] L. Chen, "High-precision state of charge estimation of lithium-ion batteries based on improved particle swarm optimization-backpropagation neural network-dual extended Kalman filtering," *Int. J. Circuit Theory Appl.*, 2023, doi: 10.1002/cta.3788.
- [9] F. Ali, "Backpropagation of Levenberg–Marquardt artificial neural networks for reverse roll coating process in the bath of Sisko fluid," *Eur. Phys. J. Plus*, vol. 138, no. 10, 2023, doi: 10.1140/epjp/s13360-023-04579-w.
- [10] J. D. Quadros, "Base drag estimation in suddenly expanded supersonic flows using backpropagation genetic and recurrent neural networks," *Proc. Inst. Mech. Eng. Part G J. Aerosp. Eng.*, vol. 236, no. 14, pp. 2991–3018, 2022, doi: 10.1177/09544100211072594.
- [11] R. V. Penmetsa, "Experimental study and machining parameter optimization on powder-mixed EDM of Nimonic 901 using feed-forward backpropagation neural networks," *Int. J. Adv. Manuf. Technol.*, 2022, doi: 10.1007/s00170-022-09297-8.
- [12] S. F. Wardhani, "COMPARISON ARTIFICIAL NEURAL NETWORK METHODS OF BACKPROPAGATION AND LEARNING VECTOR QUANTIZATION FOR FORECASTING STOCK PRICES," *J. Theor. Appl. Inf. Technol.*, vol. 100, no. 21, pp. 6674–6685, 2022.
- [13] H. Pratiwi *et al.*, "Sigmoid Activation Function in Selecting the Best Model of Artificial Neural Networks," *J. Phys. Conf. Ser.*, vol. 1471, no. 1, 2020, doi: 10.1088/1742-6596/1471/1/012010.
- [14] S. Mouloodi, "Feedforward backpropagation artificial neural networks for predicting mechanical responses in complex nonlinear structures: A study on a long bone," *J. Mech. Behav. Biomed. Mater.*, vol. 128, 2022, doi: 10.1016/j.jmbbm.2022.105079.
- [15] W. Aribowo, "Optimizing Feed Forward Backpropagation Neural Network Based on

- Teaching-Learning-Based Optimization Algorithm for Long-Term Electricity Forecasting,” *Int. J. Intell. Eng. Syst.*, vol. 15, no. 1, pp. 11–20, 2022, doi: 10.22266/IJIES2022.0228.02.
- [16] M. Tanhacean, “Optimization of backpropagation neural network models for reliability forecasting using the boxing match algorithm: electro-mechanical case,” *J. Comput. Des. Eng.*, vol. 10, no. 2, pp. 918–933, 2023, doi: 10.1093/jcde/qwad032.
- [17] D. A. Anggoro, “Comparison of Performance Metrics Level of Restricted Boltzmann Machine and Backpropagation Algorithms in Detecting Diabetes Mellitus Disease,” *Iraqi J. Sci.*, vol. 64, no. 2, pp. 907–921, 2023, doi: 10.24996/ijs.2023.64.2.35.
- [18] H. Mellah, “A Fast-Intelligent Sensor Based on Cascade-Forward Neural Network Founded by Resilient Backpropagation for Simultaneous Parameters and State Space Estimation of Brushed DC Machines,” *J. Eng. Sci. Technol. Rev.*, vol. 15, no. 2, pp. 8–14, 2022, doi: 10.25103/jestr.152.02.
- [19] M. Yang, “A hybrid approach to building simplification with an evaluator from a backpropagation neural network,” *Int. J. Geogr. Inf. Sci.*, vol. 36, no. 2, pp. 280–309, 2022, doi: 10.1080/13658816.2021.1873998.
- [20] H. Y. Li, “Strike Velocity Prediction of Stick Blunt Instruments Based on Backpropagation Neural Network,” *J. Forensic Med.*, vol. 38, no. 5, pp. 573–578, 2022, doi: 10.12116/j.issn.1004-5619.2020.401108.
- [21] Y. Xie, “An Improved Indoor Location Algorithm Based on Backpropagation Neural Network,” *Arab. J. Sci. Eng.*, vol. 47, no. 11, pp. 13823–13835, 2022, doi: 10.1007/s13369-021-06529-z.
- [22] P. T. Giang, “Experiment on Sensorless Control of an Induction Motor using Backpropagation Neural Network,” *Int. J. Eng. Trends Technol.*, vol. 70, no. 10, pp. 87–97, 2022, doi: 10.14445/22315381/IJETT-V70I10P211.
- [23] W. Guan, “Predicting buckling of carbon fiber composite cylindrical shells based on backpropagation neural network improved by sparrow search algorithm,” *J. Iron Steel Res. Int.*, vol. 30, no. 12, pp. 2459–2470, 2023, doi: 10.1007/s42243-023-00966-w.
- [24] Syaharuddin, “Investigations on Impact of Feature Normalization Techniques for Prediction of Hydro-Climatology Data Using Neural Network Backpropagation with Three Layer Hidden,” *Int. J. Sustain. Dev. Plan.*, vol. 17, no. 7, pp. 2069–2074, 2022, doi: 10.18280/ijstdp.170707.
- [25] Agus Perdana Windarto, “Implementasi Jst Dalam Menentukan Kelayakan Nasabah Pinjaman Kur Pada Bank Mandiri Mikro Serbelawan Dengan Metode Backpropogation,” *J-SAKTI (Jurnal Sains Komput. dan Inform.*, vol. 1, no. 1, pp. 12–23, 2017.
- [26] A. P. Windarto, L. S. Dewi, and D. Hartama, “Implementation of Artificial Intelligence in Predicting the Value of Indonesian Oil and Gas Exports With BP Algorithm,” *Int. J. Recent Trends Eng. Res.*, vol. 3, no. 10, pp. 1–12, 2017, doi: 10.23883/IJRTER.2017.3482.J5BBS.
- [27] B. Widodo and S. Derwin, “Artificial Intelligence konsep dan penerapannya,” *Artif. Intell. konsep dan penerapannya*, p. 168, 2014.
- [28] T. Dalglish *et al.*, *Jaringan Syaraf Tiruan (Neural Network)*, vol. 136, no. 1. 2014.
- [29] Z. A. Matodang, “Jaringan Syaraf Tiruan Dengan Algoritma Backpropagation Untuk Penentuan Kelulusan Sidang Skripsi,” *Pelita Inform. Budi Darma*, vol. 4, no. 1, pp. 84–93, 2013.
- [30] Y. A. Lesnussa, S. Latuconsina, and E. R. Persulesy, “Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Memprediksi Prestasi Siswa SMA (Studi kasus : Prediksi Prestasi Siswa SMAN 4 Ambon),” *J. Mat. Integr.*, vol. 11, no. 2, pp. 149–160, 2015.
- [31] N. M. Sukarno, P. W. Wirawan, and S. Adhy, “Perancangan dan implementasi jaringan saraf tiruan,” vol. 5, pp. 9–18, 2013.
- [32] L. Handayani and M. Adri, “Penerapan JST (Backpropagation) untuk Prediksi Curah Hujan (Studi Kasus : Kota Pekanbaru),” no. November, pp. 238–247, 2015.