



Optimalisasi JST dalam Memprediksi Kunjungan Wisatawan Mancanegara Untuk Perencanaan dan Pengembangan Pariwisata yang Efektif

Riki Winanjaya*, Harly Okprana

Program Studi Sistem Informasi, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: ¹*riki@amiktunasbangsa.ac.id, ²harly@amiktunasbangsa.ac.id

Email Penulis Korespondensi: riki@amiktunasbangsa.ac.id

Abstrak—Prediksi wisatawan mancanegara membantu pemerintah dan pemangku kepentingan dalam merencanakan strategi pariwisata jangka panjang dan pendek. Informasi yang akurat tentang perkiraan jumlah wisatawan memungkinkan pengembangan infrastruktur yang sesuai, alokasi anggaran yang efisien, dan pengaturan kebijakan yang relevan. Wisatawan mancanegara yang akan dibahas pada penelitian ini adalah wisatawan mancanegara berdasarkan negara ASEAN. Penelitian ini akan memanfaatkan data historis kunjungan wisatawan mancanegara yang bersumber dari kementerian pariwisata, Kementerian Hukum dan HAM (Direktorat Jendral Imigrasi) dan Mobile Positioning Data. Data yang telah diperoleh akan diproses dan disaring untuk mendapatkan data yang relevan dan akurat sebelum dijadikan input dalam pembuatan model Jaringan Saraf Tiruan (JST). Algoritma yang diusulkan pada penelitian ini adalah algoritma Cyclical Rule dengan optimalisasi algoritma Bayesian Regulation, yang dapat dimanfaatkan untuk menyelesaikan masalah prediksi data. Penelitian ini dianalisis menggunakan 10 (sepuluh) model arsitektur, antara lain: 4-4-1, 4-5-1, 4-8-1, 4-10-1, 4-12-1, 4-15-1, 4-16-1, 4-20-1, 4-24-1, dan 4-25-1. Berdasarkan analisis diperoleh hasil model 4-10-1 dengan optimalisasi algoritma Bayesian Regulation sebagai model terbaik dengan MSE pengujian yang paling kecil dibandingkan model lain nya, yakni sebesar 0,00786961. Berdasarkan hasil prediksi, kunjungan wisatawan mancanegara dari negara ASEAN di tahun 2023 diperkirakan akan mengalami penurunan dibandingkan tahun 2022. Para pelaku pariwisata dapat memanfaatkan hasil prediksi ini untuk meningkatkan kualitas dan kuantitas layanan yang diberikan pada wisatawan, serta menyesuaikan kebutuhan wisatawan dengan sumber daya yang tersedia di destinasi wisata.

Kata Kunci: Wisatawan Mancanegara; ASEAN; Optimalisasi; Prediksi; JST

Abstract—Foreign tourist predictions assist the government and stakeholders in planning long- and short-term tourism strategies. Accurate information on the estimated number of tourists enables appropriate infrastructure development, efficient budget allocation and setting of relevant policies. Foreign tourists discussed in this study are foreign tourists based in ASEAN countries. This research will utilize historical data on foreign tourist arrivals from the Ministry of Tourism, the Ministry of Law and Human Rights (Directorate General of Immigration) and Mobile Positioning Data. The data that has been obtained will be processed and filtered to obtain relevant and accurate data before being used as input in the creation of an Artificial Neural Network (ANN) model. The algorithm proposed in this study is the Cyclical Rule algorithm with the optimization of the Bayesian Regulation algorithm, which can be used to solve data prediction problems. This study was analyzed using 10 (ten) architectural models, including 4-4-1, 4-5-1, 4-8-1, 4-10-1, 4-12-1, 4-15-1, 4-16-1, 4-20-1, 4-24-1, and 4-25-1. Based on the analysis, the results obtained from the 4-10-1 model with the optimization of the Bayesian Regulation algorithm as the best model with the smallest testing MSE compared to the other models, equal to 0.00786961. Based on the prediction results, foreign tourist arrivals from ASEAN countries in 2023 are expected to decrease compared to 2022. Tourism actors can take advantage of the results of this prediction to improve the quality and quantity of services provided to tourists, as well as adjust the needs of tourists with the resources available at tourist destinations.

Keywords: International Tourists; ASEAN; Optimization; Predictions; ANN

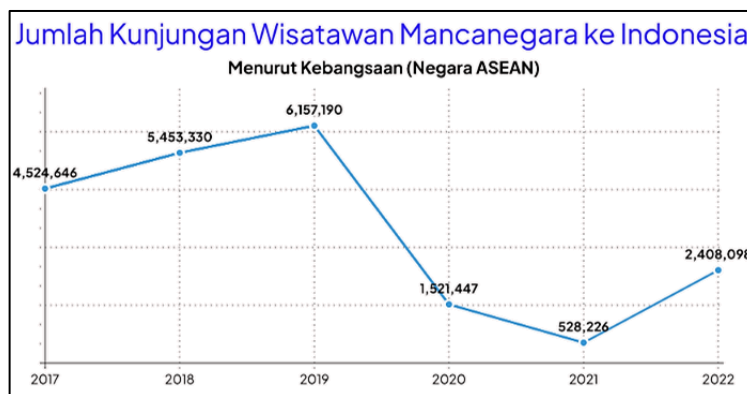
1. PENDAHULUAN

Pentingnya sektor pariwisata sebagai salah satu sektor ekonomi yang strategis di Indonesia [1]–[3], menjadikan penelitian terkait hal ini sangat dibutuhkan, karena Indonesia memiliki potensi wisata alam dan budaya yang kaya [4]–[8]. Pada era globalisasi dan kemajuan teknologi, prediksi kunjungan wisatawan mancanegara menjadi salah satu hal yang penting bagi perencanaan dan pengembangan pariwisata yang efektif. Sehingga diusulkan proposal ini, dengan tujuan untuk memprediksi kunjungan wisatawan mancanegara berdasarkan kebangsaan negara ASEAN, hal ini karena negara ASEAN yang paling banyak mengunjungi Indonesia. Salah satu metode yang dapat digunakan untuk memprediksi kunjungan wisatawan mancanegara adalah dengan menggunakan Jaringan Saraf Tiruan (JST) atau Artificial Neural Network (ANN). JST merupakan suatu model komputasi yang terinspirasi dari cara kerja otak manusia dalam memproses informasi dan belajar dari data yang ada [9]–[11]. JST telah banyak digunakan dalam berbagai aplikasi, termasuk prediksi dalam bidang pariwisata [12]–[17]. Namun, meskipun JST telah banyak digunakan dalam prediksi kunjungan wisatawan mancanegara, terdapat potensi untuk mengoptimalkan performa JST tersebut. Beberapa masalah yang dihadapi dalam penggunaan JST dalam memprediksi kunjungan wisatawan mancanegara antara lain ketidakakuratan prediksi, kesalahan dalam pemilihan variabel input dan output, serta pemilihan arsitektur JST yang kurang optimal [18]. Oleh karena itu, penelitian ini akan mengusulkan algoritma JST Cyclical Rule dengan optimalisasi algoritma Bayesian Regulation dalam memprediksi kunjungan wisatawan mancanegara untuk perencanaan dan pengembangan pariwisata yang lebih efektif. Algoritma Bayesian Regulation (Bayesian Regularization) mampu memberikan kesalahan standar empiris, melalui pendekatan ilmu pengetahuan yang berfokus pada pengamatan, pengalaman langsung, dan data yang dapat



diamati. Pendekatan empiris ini didasarkan pada bukti-bukti konkret yang dapat dilihat, diukur, atau diobservasi [19]. Penelitian ini juga akan menggali data historis kunjungan wisatawan mancanegara yang ada, baik dalam bentuk data statistik maupun data time series, untuk mengembangkan model JST yang lebih akurat dan efektif. Sebagai langkah mengoptimalkan JST, penelitian ini juga akan mempertimbangkan pemilihan variabel input dan output yang tepat, serta pemilihan arsitektur JST yang sesuai, seperti jumlah neuron, fungsi aktivasi, dan metode pembelajaran yang optimal. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi bagi perencanaan dan pengembangan pariwisata yang lebih efektif, dengan menghasilkan model JST yang akurat dalam memprediksi kunjungan wisatawan mancanegara. Selain itu, penelitian ini juga diharapkan dapat memberikan pemahaman yang lebih baik tentang perkembangan kunjungan wisatawan mancanegara di Indonesia, sehingga dapat digunakan sebagai dasar dalam pengambilan kebijakan dan strategi pengembangan pariwisata di masa depan.

Berdasarkan data Badan Pusat Statistik Indonesia yang bersumber dari Kementerian Hukum dan HAM (Direktorat Jenderal Imigrasi) dan Mobile Positioning Data, pada tahun 2020 jumlah kunjungan wisatawan mancanegara dari negara ASEAN yang datang ke Indonesia sangat turun drastis dibandingkan tahun 2019. Lebih parah lagi penurunan jumlah wisatawan mancanegara terjadi pada tahun 2021 yang tidak sampai 1 juta orang. Kendati demikian di tahun 2022 jumlah wisatawan sudah semakin meningkat dengan tidak kurang dari 2 juta wisatawan yang datang ke Indonesia [20]. Grafik perbandingan jumlah kunjungan wisatawan mancanegara ke Indonesia menurut kebangsaan (Negara ASEAN) dapat dilihat pada gambar 1 berikut.



Gambar 1. Jumlah Kunjungan Wisatawan Mancanegara ke Indonesia Menurut Kebangsaan (ASEAN) [20]

Berdasarkan gambar 1 terlihat bahwa tren kunjungan wisatawan tahun 2017 hingga tahun 2019 semakin meningkat, akan tetapi saat wabah covid-19 melanda di tahun 2020 hingga tahun 2021 tren nya berubah sehingga kunjungan wisatawan sangat merosot drastis hingga hanya 500 ribuan wisatawan saja yang berkunjung ke Indonesia. Pada tahun 2022 kondisi ini semakin membaik seiring mulai redanya pandemic Covid-19, terbukti jumlah wisatawan yang berkunjung ke Indonesia di tahun tersebut lebih dari 2 juta wisatawan. Akan tetapi kondisi ini bisa saja berubah kembali apabila sektor pariwisata tidak segera dibenahi.

State of the art terkait penelitian ini diantaranya: Penelitian yang dilakukan oleh (Hu, Li, Song, Li, & Law, 2022) untuk meramalkan kedatangan turis internasional ke Hong Kong dari tujuh negara berbahasa Inggris menggunakan teknik Mixed Data Sampling (MIDAS). Perbedaan penelitian ini dengan penelitian yang akan dilakukan terletak pada algoritma yang digunakan dan model yang dihasilkan. Penelitian ini menggunakan MIDAS, sedangkan penelitian yang diusulkan menggunakan algoritma JST standard seperti back-propagation yang di optimalisasi dengan menggunakan kombinasi teknik JST lainnya seperti Bayesian Regulation [21].

(Dong, Xiao, Wang, & Wang, 2023) mengusulkan model baru untuk peramalan permintaan pariwisata berdasarkan perhatian yang dipandu oleh mekanisme yang dikembangkan. Penelitian ini membandingkan model SARIMA, ARIMAX [22], Grey-based Model [23], ANN-based model [24], RNN-based model [25], dan model yang mereka usulkan [26]. Berdasarkan perbandingan dari keseluruhan model, model yang diusulkan (Extreme Learning Machine / ELM) menjadi model yang terbaik. Perbedaan penelitian ini dengan penelitian yang akan dilakukan terletak pada algoritma yang digunakan dan model yang dihasilkan. Penelitian ini menggunakan algoritma JST Extreme Learning Machine, sedangkan penelitian yang diusulkan menggunakan algoritma JST yang berbeda yang dioptimisasi dengan menggunakan kombinasi algoritma JST yang berbeda pula.

(Mu'minin & Gunaryati, 2022) melakukan penelitian dengan membandingkan algoritma ARIMA, Glnet, dan Prophet untuk memprediksi kunjungan wisatawan mancanegara. Hasil penelitian ini menunjukkan model ARIMA merupakan model terbaik untuk melakukan prediksi dibandingkan model Prophet dan Glnet karena menghasilkan nilai terbaik pada MAE, MAPE, MASE, SMAPE, dan RMSE [27]. Perbedaan penelitian ini dengan penelitian yang diusulkan terletak pada algoritma yang digunakan dan dibandingkan. Penelitian yang diusulkan akan menggunakan algoritma JST Cyclical Rule yang akan di optimalisasi dengan menggunakan algoritma Bayesian Regulation dengan tolak ukur pemilihan model terbaik untuk melakukan prediksi dilihat dari nilai Mean Square Error (MSE) yang terendah.

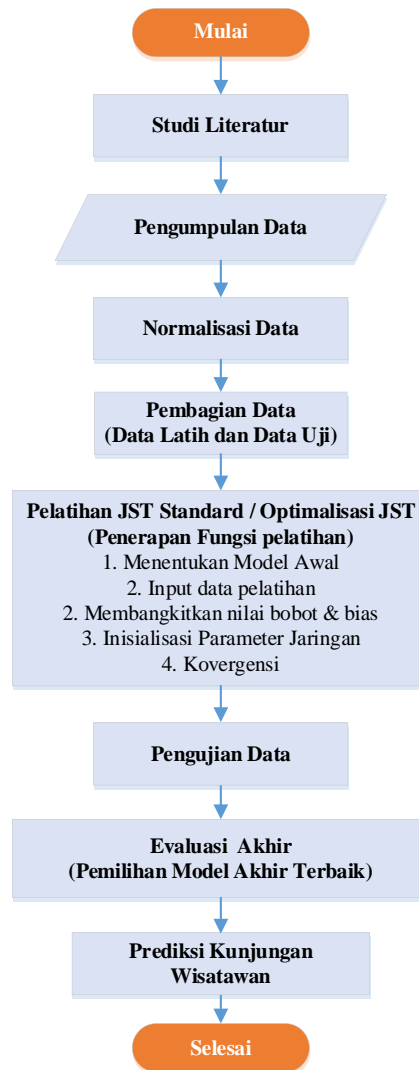


Penelitian lain yang menjadi rujukan, diantaranya: (Mukhtar, Gunawan, Hariyanto, Syahril, & Wide Mulyana, 2022) melakukan peramalan kedatangan wisatawan dengan SVM [28], (Ridla, Azise, & Rahman, 2023) membandingkan metode SARIMA, LSTM, dan Prophet berdasarkan data times series untuk prediksi kedatangan wisatawan [29], (Riestiansyah, Damayanti, Reswara, & Susetyoko, 2022) menggunakan perbandingan metode ARIMA dan ARIMAX [30], dan (Fatimatuzzahra, Hammad, Amrullah, & Irfan, 2022) menggunakan optimasi algoritma Genetika untuk memprediksi jumlah kunjungan wisatawan [31].

Berdasarkan resume dari penelitian-penelitian tersebut, maka kebaruan yang ditawarkan dari usulan penelitian ini yaitu Optimalisasi JST Cyclical Rule dengan algoritma Bayesian Regulation dalam memprediksi kunjungan wisatawan mancanegara. Penggunaan teknik atau pendekatan optimalisasi dalam menggabungkan atau meningkatkan kinerja JST dalam memprediksi kunjungan wisatawan mancanegara. Optimalisasi JST dapat membantu dalam meningkatkan akurasi dan efektivitas prediksi kunjungan wisatawan mancanegara, yang pada gilirannya dapat digunakan sebagai informasi awal agar perencanaan dan pengembangan pariwisata yang akan dilakukan menjadi lebih efektif.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian



Gambar 2. Tahapan Penelitian

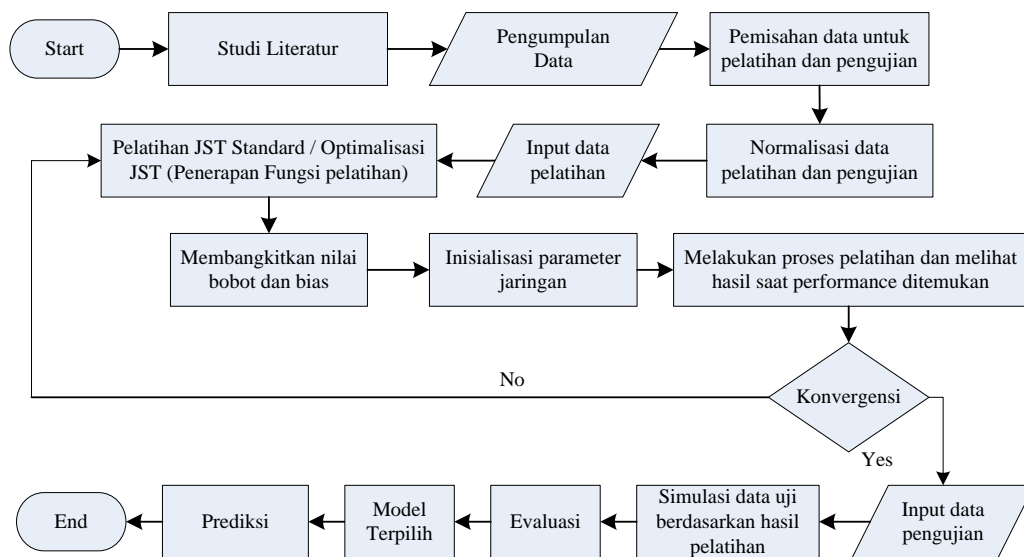
Masing-masing tahapan dapat dijelaskan sebagai berikut:

- a. Studi Literatur
Mengumpulkan dan menelaah literatur, artikel, jurnal, buku, dan sumber-sumber informasi lain yang berkaitan dengan topik penelitian.
- b. Pengumpulan Data
Tahap awal dalam penelitian ini adalah mengumpulkan data jumlah kunjungan wisatawan di Indonesia. Data tersebut akan digunakan sebagai masukan untuk proses selanjutnya.



- c. Normalisasi Data
Dataset penelitian akan di normalisasi terlebih dahulu sebelum di proses menggunakan algoritma JST.
- d. Pembagian Data (Data Latih dan data Uji)
Data pelatihan dan pengujian merujuk pada dua jenis data yang digunakan dalam proses pengembangan dan evaluasi model machine learning (JST). Data pelatihan digunakan untuk melatih model JST. Data ini digunakan untuk mengajar model bagaimana harus melakukan prediksi atau tugas tertentu dengan baik. Data pengujian adalah data yang digunakan untuk menguji kinerja model setelah proses pelatihan selesai. Data ini digunakan untuk mengukur seberapa baik model dapat melakukan prediksi.
- e. Pelatihan JST Standard / Optimalisasi JST (Penerapan Fungsi pelatihan)
Tahap ini merupakan proses di mana model JST awal dibangun, kemudian diberikan input data pelatihan untuk mempelajari pola-pola yang ada dalam data tersebut. Salah satu aspek penting dalam pelatihan JST adalah pemilihan fungsi pelatihan atau algoritma optimisasi yang digunakan untuk mengoptimalkan bobot dan bias dalam jaringan sara tiruan.
- f. Pengujian Data
Tujuan dari pengujian data adalah untuk memastikan bahwa model atau sistem yang telah dilatih dengan data pelatihan mampu meng-generalisasi dan bekerja dengan baik pada data baru yang belum pernah dilihat sebelumnya.
- g. Evaluasi Akhir (Pemilihan Model Akhir Terbaik)
Tahap ini merupakan Tahap terakhir dalam proses optimalisasi model atau algoritma JST, setelah melalui tahap pelatihan, validasi, dan pemilihan model.
- h. Prediksi Kunjungan Wisatawan Mancanegara
Tahap terakhir dalam penelitian ini adalah melakukan prediksi kunjungan wisatawan mancanegara ke Indonesia menggunakan model JST yang terbaik.

2.2 Flowchart Penelitian



Gambar 3. Flowchart Penelitian

Pada Gambar 3 dapat dijelaskan bahwa langkah pertama yang dilakukan dari tahapan penelitian adalah melakukan studi pustaka dan mengumpulkan dataset penelitian (berdasarkan tabel 1). Tahapan selanjutnya adalah memisahkan data penelitian menjadi 2 (dua) bagian, yakni bagian pelatihan dan pengujian. Tahapan berikutnya melakukan normalisasi data pelatihan dan pengujian dengan menggunakan rumus persamaan 1 [32]–[35].

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

Dimana : x' adalah hasil data yang sudah di normalisasi, 0.8 dan 0.1 adalah nilai default, x (data yang akan di normalisasi), a dan b adalah nilai terendah dan nilai tertinggi dari data penelitian yang digunakan. Selanjutnya dimasukkan data pelatihan yang sudah di normalisasi agar diproses menggunakan aplikasi Matlab untuk di proses, tahapan berikutnya membuat multi layer jaringan saraf dengan menerapkan JST standard setelah itu dilakukan optimasi dengan pemilihan fungsi pelatihan atau aktivasi. Model arsitektur jaringan untuk proses pelatihan menggunakan input layer, hidden layer dan 1 layer keluaran. Pembuatan multi layer jaringan saraf tradisional pada layer tersembunyi direncanakan menggunakan fungsi aktivasi tansig (sigmoid tangen) dan layer keluaran menggunakan logsig (sigmoid biner), sedangkan Pembuatan multi layer jaringan saraf untuk optimasi pada layer tersembunyi menggunakan fungsi aktivasi tansig (sigmoid tangen) dan layer keluaran menggunakan purelin (fungsi linier). Pada bagian ini juga menerapkan fungsi pelatihan, dengan data pelatihan masing-masing



akan dilatih secara silih berganti. Tahapan berikutnya adalah membangkitkan nilai IW dan LW (bobot) dan bias (b). Selanjutnya berdasarkan fungsi pelatihan yang digunakan dilakukan inisialisasi parameter jaringan. Kemudian memasukkan perintah untuk dilakukan proses pelatihan dan melihat hasil saat ditemukan kinerja (performance). Apabila hasil pelatihan mencapai konvergensi, maka akan dilanjutkan memasukkan data pengujian yang sudah di normalisasi. Tetapi jika hasil pelatihan belum mencapai konvergensi, maka kembali ke tahap pembuatan jaringan saraf standard dan optimasi jaringan. Tahapan berikutnya dilanjutkan dengan simulasi data uji berdasarkan hasil pelatihan. Apabila semua sudah dilakukan, tahapan akhir adalah dilakukan evaluasi untuk melihat kinerja metode JST apakah dapat melakukan optimasi pelatihan yang sebelumnya telah dilakukan dengan menggunakan algoritma standard, hasil evaluasi nantinya akan memperoleh model jaringan terbaik yang akan digunakan untuk melakukan prediksi.

2.3 Dataset Penelitian

Dataset penelitian merupakan data historis kunjungan wisatawan mancanegara dari negara ASEAN yang bersumber dari kementerian pariwisata, Kementerian Hukum dan HAM (Direktorat Jendral Imigrasi) dan Mobile Positioning Data yang dipublikasikan pada website Badan Pusat Statistik Indonesia [20].

Tabel 1. Jumlah Kunjungan Wisatawan Mancanegara ke Indonesia Menurut Kebangsaan (ASEAN)

No	Kebangsaan	2017	2018	2019	2020	2021	2022
1	Brunei Darussalam	23.455	17.279	19.278	2.701	144	4.798
2	Malaysia	2.121.888	2.503.344	2.980.753	980.118	480.723	1.212.574
3	Philippines	308.977	217.874	260.980	50.413	9.375	78.436
4	Singapore	1.554.119	1.768.744	1.934.445	280.492	18.704	736.797
5	Thailand	138.235	124.153	136.699	21.303	3.992	61.128
6	Vietnam	77.466	75.816	96.024	19.608	2.008	68.067
7	Myanmar	48.133	28.612	46.381	12.669	3.093	22.637
8	Asean Lainnya	252.373	717.508	682.630	154.143	10.187	223.661
	Total ASEAN	4.524.646	5.453.330	6.157.190	1.521.447	528.226	2.408.098

2.4 Algoritma Cyclical Rule

Metode Cyclical Rule / Cyclical Order weight/bias merupakan salah satu metode dari Jaringan Saraf Tiruan. Metode Cyclical Order weight/bias merupakan metode jaringan saraf tiruan yang melatih jaringan dengan aturan pembelajaran berat dan bias dengan pembaharuan tambahan setelah data yang disajikan di input. Data yang di input disajikan dalam urutan yang tersusun secara melingkar [36].

Syntax umum metode Cyclical Rule / Cyclical Order weight/bias (trainc) yaitu :

$$[\text{net}, \text{TR}] = \text{trainc}(\text{net}, \text{TR}, \text{trainV}, \text{valV}, \text{testV}) \quad (2)$$

$$\text{info} = \text{trainc}(\text{'info'}) \quad (3)$$

Keterangan :

trainc tidak dipanggil secara langsung. Sebaliknya dipanggil dengan pelatihan (train) untuk membangun jaringan yang properti net.trainFcn nya diatur ke 'trainc'.

[net, TR] = trainc(net, TR, trainV, valV, testV) : Perintah untuk membangun jaringan

Net : Jaringan Syaraf

TR : Catatan pelatihan awal dibuat dengan train

trainV : Data pelatihan dibuat dengan train

valV : Data validasi dibuat dengan train

testV : Uji data yang dibuat dengan train dan kembali,

net : Jaringan yang terlatih

TR : Catatan pelatihan berbagai nilai selama Epoch berlangsung.

2.5 Algoritma Bayesian Regulation

Algoritma Bayesian Regulation merupakan fungsi pelatihan jaringan yang memperbarui bobot dan nilai bias sesuai dengan optimasi Levenberg-Marquardt. Hal ini dengan meminimalkan kombinasi kesalahan kuadrat dan bobot, dan kemudian menentukan kombinasi yang benar sehingga menghasilkan jaringan yang digeneralisasi dengan baik. Teknik Bayesian Regulation dapat dirumuskan sebagai berikut:

$$[\text{net}, \text{TR}] = \text{trainbr}(\text{net}, \text{TR}, \text{trainV}, \text{valV}, \text{testV}) \quad (4)$$

Keterangan :

net = Pembentukan Jaringan Syaraf

TR = Catatan pelatihan awal yang dibuat berdasarkan data latih

trainV = Data pelatihan yang dibuat berdasarkan data latih

valV = Data validasi yang dibuat berdasarkan data latih



testV = Data uji yang dibuat berdasarkan data latih

3. HASIL DAN PEMBAHASAN

3.1 Normalisasi untuk Pelatihan dan Pengujian Kinerja

Dataset penelitian berdasarkan tabel 1 dinormalisasi terlebih dahulu menggunakan persamaan (1). Selanjutnya dibagi menjadi 2 bagian, yakni untuk data latih dan data uji. Data latih diambil dari tahun 2017-2020 dengan target pelatihan tahun 2021. Sedangkan untuk data pengujian berdasarkan data tahun 2018-2021 dengan target tahun 2022. Hasil Normalisasi data dapat dilihat pada tabel 2 berikut.

Tabel 2. Hasil Normalisasi

Data	Training				Target	Testing				Target
	2017	2018	2019	2020	(2021)	2018	2019	2020	2021	(2022)
1	0,10626	0,10460	0,10514	0,10069	0,10000	0,10460	0,10514	0,10069	0,10000	0,10125
2	0,66948	0,77186	0,90000	0,36303	0,22899	0,77186	0,90000	0,36303	0,22899	0,42542
3	0,18289	0,15844	0,17001	0,11349	0,10248	0,15844	0,17001	0,11349	0,10248	0,12101
4	0,51709	0,57469	0,61917	0,17525	0,10498	0,57469	0,61917	0,17525	0,10498	0,29772
5	0,13706	0,13328	0,13665	0,10568	0,10103	0,13328	0,13665	0,10568	0,10103	0,11637
6	0,12075	0,12031	0,12573	0,10522	0,10050	0,12031	0,12573	0,10522	0,10050	0,11823
7	0,11288	0,10764	0,11241	0,10336	0,10079	0,10764	0,11241	0,10336	0,10079	0,10604
8	0,16770	0,29254	0,28318	0,14133	0,10270	0,29254	0,28318	0,14133	0,10270	0,15999

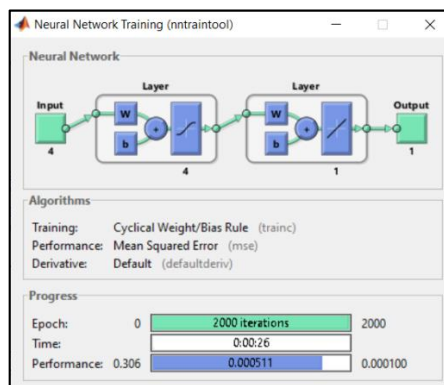
3.2 Hasil Pelatihan dan Kinerja

Proses pelatihan untuk melihat kemampuan / kinerja dari algoritma Cyclical Rule yang di optimalisasi dengan algoritma Bayesian Regulation, dilakukan dengan memanfaatkan aplikasi MATLAB 2011b menggunakan 10 (sepuluh) model arsitektur, antara lain: 4-4-1, 4-5-1, 4-8-1, 4-10-1, 4-12-1, 4-15-1, 4-16-1, 4-20-1, 4-24-1, dan 4-25-1. Karena banyaknya model yang digunakan, maka pada makalah ini akan dituliskan 4 (empat) model saja yang mewakili keseluruhan model yang digunakan, yakni: 4-4-1, 4-10-1, dan 4-15-1.

a. Model Arsitektur 4-4-1

1. Algoritma Cyclical Rule

Tampilan hasil training algoritma Cyclical Rule dengan arsitektur 4-4-1 dapat dilihat pada Gambar 4. Pelatihan algoritma Cyclical Rule dengan fungsi aktivasi tansig dan purelin pada arsitektur ini mengalami over fitting dan tidak konvergensi, karena sampai batas epoch (2000) yang ditentukan, Performance nya tidak dapat menyelesaikan training dengan baik.



Gambar 4. Hasil Training Cyclical Rule dengan Arsitektur 4-4-1

Hasil pelatihan dan pengujian terhadap arsitektur 4-4-1 pada algoritma Cyclical Rule (trainc), dapat dilihat pada Tabel 3. Target pelatihan dan pengujian diperoleh dari tabel normalisasi. Output diperoleh dari perhitungan Matlab. Error diperoleh dari Target-Output. SSE diperoleh dari Error ². Jumlah SSE diperoleh dari Total SSE secara keseluruhan. MSE/Perf diperoleh dari Jumlah SSE dibagi banyaknya data (Jumlah SSE / 8). Sehingga menghasilkan Jumlah SSE training 0,00408905 dan MSE/Perf sebesar 0,00051113. Sedangkan Jumlah SSE Testing 1,07206956 dan MSE/Perf sebesar 0,13400869.

Tabel 3. Pelatihan Arsitektur 4-4-1 pada Algoritma Cyclical Rule (trainc)

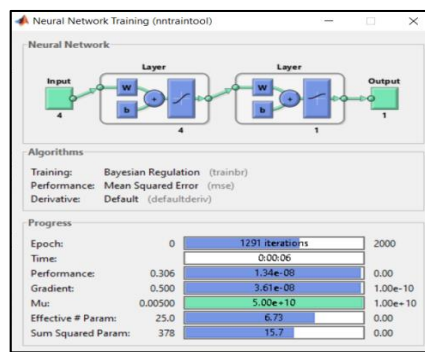
Data Pelatihan					Data Pengujian			
Data	Target	Output	Error	SSE	Target	Output	Error	SSE
1	0,10000	0,07800	0,02200	0,00048400	0,10125	0,07210	0,02915	0,00084967



Data Pelatihan					Data Pengujian			
Data	Target	Output	Error	SSE	Target	Output	Error	SSE
2	0,22899	0,22780	0,00119	0,00000141	0,42542	-0,37130	0,79672	0,63475967
3	0,10248	0,14590	-0,04342	0,00188550	0,12101	0,10510	0,01591	0,00025325
4	0,10498	0,10600	-0,00102	0,00000104	0,29772	-0,33340	0,63112	0,39831092
5	0,10103	0,12140	-0,02037	0,00041482	0,11637	0,09700	0,01937	0,00037513
6	0,10050	0,10270	-0,00220	0,00000484	0,11823	0,08830	0,02993	0,00089584
7	0,10079	0,08780	0,01299	0,00016878	0,10604	0,07530	0,03074	0,00094477
8	0,10270	0,06910	0,03360	0,00112866	0,15999	-0,02890	0,18889	0,03568030
				Jumlah SSE				1,07206956
				MSE / Perf				0,13400869

2. Algoritma Bayesian Regulation

Tampilan hasil training algoritma Bayesian Regulation dengan arsitektur 4-4-1 dapat dilihat pada Gambar 5. Pelatihan algoritma Bayesian Regulation dengan fungsi aktivasi tansig dan logsig pada arsitektur ini menghasilkan epoch sebesar 1291 iterasi (konvergensi) dengan waktu selama 6 (enam) detik.



Gambar 5. Hasil Training Bayesian Regulation dengan Arsitektur 4-4-1

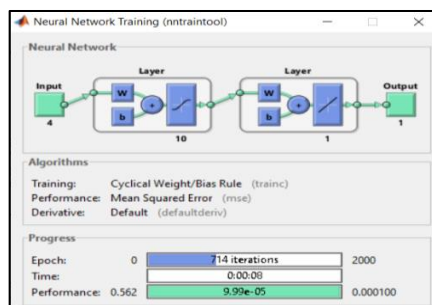
Hasil pelatihan dan pengujian terhadap arsitektur 4-4-1 pada algoritma Bayesian Regulation (trainbr), dapat dilihat pada Tabel 4. Jumlah SSE pada data pelatihan sebesar 0,00000011 dan MSE/Perf 0,00000001. Sedangkan Jumlah SSE data pengujian sebesar 0,07232127 dan MSE/Perf 0,00904016.

Tabel 4. Pelatihan Arsitektur 4-4-1 pada Algoritma Bayesian Regulation (trainbr)

Data Pelatihan					Data Pengujian			
Data	Target	Output	Error	SSE	Target	Output	Error	SSE
1	0,10000	0,10010	-0,00010	0,00000001	0,10125	0,10020	0,00105	0,00000110
2	0,22899	0,22900	-0,00001	0,00000000	0,42542	0,22080	0,20462	0,04186855
3	0,10248	0,10250	-0,00002	0,00000000	0,12101	0,10420	0,01681	0,00028270
4	0,10498	0,10500	-0,00002	0,00000000	0,29772	0,13280	0,16492	0,02719821
5	0,10103	0,10090	0,00013	0,00000002	0,11637	0,10240	0,01397	0,00019511
6	0,10050	0,10070	-0,00020	0,00000004	0,11823	0,10130	0,01693	0,00028665
7	0,10079	0,10060	0,00019	0,00000004	0,10604	0,10060	0,00544	0,00002956
8	0,10270	0,10270	0,00000	0,00000000	0,15999	0,11040	0,04959	0,00245940
				Jumlah SSE				0,07232127
				MSE				0,00904016

b. Model Arsitektur 4-10-1

1. Algoritma Cyclical Rule



Gambar 6. Hasil Training Cyclical Rule dengan Arsitektur 4-10-1



Tampilan hasil training algoritma Cyclical Rule dengan arsitektur 4-10-1 dapat dilihat pada Gambar 6. Pelatihan algoritma Cyclical Rule dengan fungsi aktivasi tansig dan purelin pada arsitektur ini tidak mengalami over fitting seperti pada arsitektur 4-4-1. Arsitektur ini menghasilkan epoch sebesar 714 iterasi (konvergensi) dengan waktu selama 8 (delapan) detik.

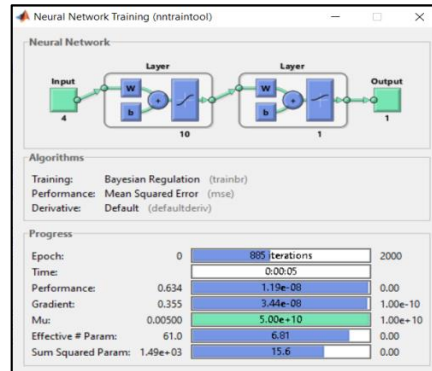
Hasil pelatihan dan pengujian terhadap arsitektur 4-10-1 pada algoritma Cyclical Rule (trainc), dapat dilihat pada Tabel 5. Output diperoleh dari hasil perhitungan menggunakan Matlab. Error diperoleh dari Target-Output. SSE diperoleh dari $Error^2$. Jumlah SSE diperoleh dari Total SSE secara keseluruhan. MSE/Perf diperoleh dari Jumlah SSE dibagi banyaknya data (Jumlah SSE / 8). Sehingga data pelatihan menghasilkan Jumlah SSE 0,00079933 dan MSE/Perf sebesar 0,00009992. Sedangkan data pengujian menghasilkan Jumlah SSE 1,09606293 dan MSE/Perf sebesar 0,13700787.

Tabel 5. Pelatihan Arsitektur 4-10-1 pada Algoritma Cyclical Rule (trainc)

Data Pelatihan					Data Pengujian			
Data	Target	Output	Error	SSE	Target	Output	Error	SSE
1	0,10000	0,10420	-0,00420	0,00001764	0,10125	0,10630	-0,00505	0,00002551
2	0,22899	0,22870	0,00029	0,00000008	0,42542	-0,26260	0,68802	0,47336885
3	0,10248	0,07730	0,02518	0,00063391	0,12101	0,08690	0,03411	0,00116374
4	0,10498	0,10620	-0,00122	0,00000148	0,29772	-0,35260	0,65032	0,42291453
5	0,10103	0,10510	-0,00407	0,00001654	0,11637	0,10490	0,01147	0,00013152
6	0,10050	0,11040	-0,00990	0,00009800	0,11823	0,11190	0,00633	0,00004008
7	0,10079	0,10130	-0,00051	0,00000026	0,10604	0,11270	-0,00666	0,00004439
8	0,10270	0,10830	-0,00560	0,00003141	0,15999	-0,28540	0,44539	0,19837430
				Jumlah SSE				1,09606293
				MSE / Perf				0,13700787

2. Algoritma Bayesian Regulation

Tampilan hasil training algoritma Bayesian Regulation dengan arsitektur 4-10-1 dapat dilihat pada Gambar 7. Pelatihan algoritma Bayesian Regulation dengan fungsi aktivasi tansig dan logsig pada arsitektur ini menghasilkan epoch sebesar 885 iterasi (konvergensi) dengan waktu selama 5 (lima) detik.



Gambar 7. Hasil Training Bayesian Regulation dengan Arsitektur 4-10-1

Hasil pelatihan dan pengujian terhadap arsitektur 4-10-1 pada algoritma Bayesian Regulation (trainbr), dapat dilihat pada Tabel 6. Pada data pelatihan menghasilkan Jumlah SSE 0,00000011 dan MSE/Perf sebesar 0,00000001. Sedangkan pada data pengujian menghasilkan Jumlah SSE 0,06295690 dan MSE/Perf sebesar 0,00786961.

Tabel 6. Pelatihan Arsitektur 4-10-1 pada Algoritma Bayesian Regulation (trainbr)

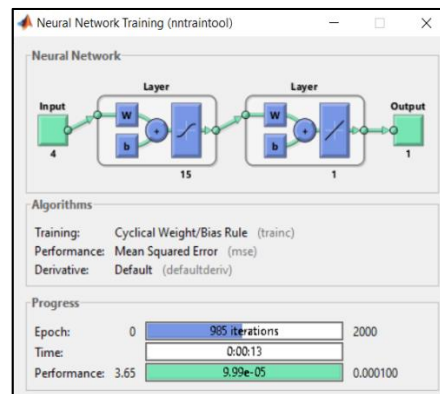
Data Pelatihan					Data Pengujian			
Data	Target	Output	Error	SSE	Target	Output	Error	SSE
1	0,10000	0,10010	-0,00010	0,00000001	0,10125	0,10030	0,00095	0,00000090
2	0,22899	0,22900	-0,00001	0,00000000	0,42542	0,23560	0,18982	0,03603090
3	0,10248	0,10250	-0,00002	0,00000000	0,12101	0,10560	0,01541	0,00023758
4	0,10498	0,10500	-0,00002	0,00000000	0,29772	0,14260	0,15512	0,02406184
5	0,10103	0,10090	0,00013	0,00000002	0,11637	0,10310	0,01327	0,00017605
6	0,10050	0,10070	-0,00020	0,00000004	0,11823	0,10180	0,01643	0,00026997
7	0,10079	0,10060	0,00019	0,00000004	0,10604	0,10080	0,00524	0,00002743
8	0,10270	0,10270	0,00000	0,00000000	0,15999	0,11360	0,04639	0,00215225
				Jumlah SSE				0,06295690
				MSE				0,00786961



c. Model Arsitektur 4-15-1

1. Algoritma Cyclical Rule

Tampilan hasil training algoritma Cyclical Rule dengan arsitektur 4-15-1 dapat dilihat pada Gambar 8. Pelatihan algoritma Cyclical Rule dengan fungsi aktivasi tansig dan purelin pada arsitektur ini juga tidak mengalami over fitting. Arsitektur ini menghasilkan epoch sebesar 985 iterasi (konvergensi) dengan waktu selama 13 (tiga belas) detik.



Gambar 8. Hasil Training Cyclical Rule dengan Arsitektur 4-15-1

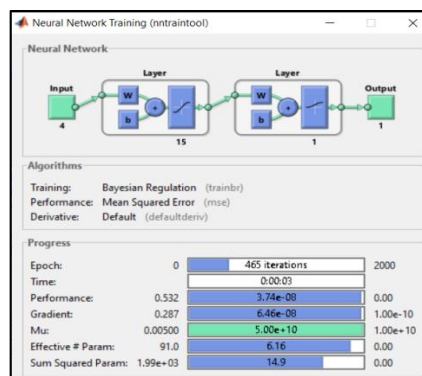
Hasil pelatihan dan pengujian terhadap arsitektur 4-15-1 pada algoritma Cyclical Rule (trainc), dapat dilihat pada Tabel 7. Pada Tabel 7 dapat dilihat bahwa Target diperoleh dari tabel normalisasi. Output diperoleh dari hasil perhitungan menggunakan Matlab. Error diperoleh dari Target-Output. SSE diperoleh dari $Error^2$. Jumlah SSE diperoleh dari Total SSE secara keseluruhan. MSE/Perf diperoleh dari Jumlah SSE dibagi banyaknya data (Jumlah SSE / 8). Sehingga menghasilkan Jumlah SSE data pelatihan sebesar 0,00079840 dan MSE/Perf sebesar 0,00009980. Sedangkan pada data pengujian menghasilkan Jumlah SSE 0,21111510 dan MSE/Perf sebesar 0,02638939.

Tabel 7. Pelatihan Arsitektur 4-15-1 pada Algoritma Cyclical Rule (trainc)

Data Pelatihan					Data Pengujian			
Data	Target	Output	Error	SSE	Target	Output	Error	SSE
1	0,10000	0,08810	0,01190	0,00014161	0,10125	0,08480	0,01645	0,00027057
2	0,22899	0,22930	-0,00031	0,00000010	0,42542	0,61120	-0,18578	0,03451493
3	0,10248	0,10570	-0,00322	0,00001038	0,12101	0,07540	0,04561	0,00208061
4	0,10498	0,10250	0,00248	0,00000616	0,29772	0,70180	-0,40408	0,16328163
5	0,10103	0,10160	-0,00057	0,00000032	0,11637	0,07650	0,03987	0,00158947
6	0,10050	0,09790	0,00260	0,00000676	0,11823	0,08160	0,03663	0,00134180
7	0,10079	0,09060	0,01019	0,00010387	0,10604	0,08480	0,02124	0,00045102
8	0,10270	0,12570	-0,02300	0,00052920	0,15999	0,07290	0,08709	0,00758507
				Jumlah SSE				0,21111510
				MSE / Perf				0,02638939

2. Algoritma Bayesian Regulation

Tampilan hasil training algoritma Bayesian Regulation dengan arsitektur 4-15-1 dapat dilihat pada Gambar 9. Pelatihan algoritma Bayesian Regulation dengan fungsi aktivasi tansig dan logsig pada arsitektur ini menghasilkan epoch sebesar 465 iterasi (konvergensi) dengan waktu selama 3 (tiga) detik.



Gambar 9. Hasil Training Bayesian Regulation dengan Arsitektur 4-15-1



Hasil pelatihan dan pengujian terhadap arsitektur 4-15-1 pada algoritma Bayesian Regulation (trainbr), dapat dilihat pada Tabel 8. Pada data pelatihan menghasilkan Jumlah SSE 0,00000035 dan MSE/Perf sebesar 0,00000004. Sedangkan data pengujian menghasilkan Jumlah SSE 0,09105582 dan MSE/Perf sebesar 0,01138198.

Tabel 8. Pelatihan Arsitektur 4-15-1 pada Algoritma Bayesian Regulation (trainbr)

Data Pelatihan					Data Pengujian				
Data	Target	Output	Error	SSE	Target	Output	Error	SSE	
1	0,10000	0,10020	-0,00020	0,00000004	0,10125	0,10020	0,00105	0,00000110	
2	0,22899	0,22900	-0,00001	0,00000000	0,42542	0,19190	0,23352	0,05453068	
3	0,10248	0,10260	-0,00012	0,00000001	0,12101	0,10220	0,01881	0,00035396	
4	0,10498	0,10500	-0,00002	0,00000000	0,29772	0,11700	0,18072	0,03265928	
5	0,10103	0,10050	0,00053	0,00000028	0,11637	0,10140	0,01497	0,00022405	
6	0,10050	0,10060	-0,00010	0,00000001	0,11823	0,10070	0,01753	0,00030732	
7	0,10079	0,10080	-0,00001	0,00000000	0,10604	0,10040	0,00564	0,00003178	
8	0,10270	0,10270	0,00000	0,00000000	0,15999	0,10570	0,05429	0,00294765	
				Jumlah SSE				Jumlah SSE	0,09105582
				MSE				MSE	0,01138198

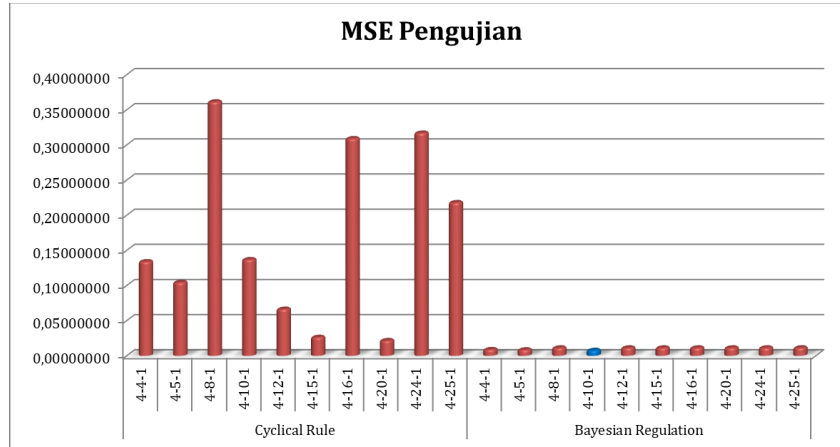
3.3 Analisis dan Evaluasi

Berdasarkan hasil pelatihan dan pengujian dari arsitektur 4-4-1, 4-5-1, 4-8-1, 4-10-1, 4-12-1, 4-15-1, 4-16-1, 4-20-1, 4-24-1, dan 4-25-1 dengan menggunakan algoritma Cyclical Rule (trainc) dengan fungsi aktivasi tansig dan purelin, serta algoritma Bayesian Regulation (trainbr) dengan fungsi aktivasi tansig dan logsig dapat dilihat kemampuan dan kinerja dari masing-masing algoritma dan arsitektur, seperti yang tersaji pada tabel 9 berikut.

Tabel 9. Analisis dan Evaluasi kemampuan dan kinerja dari masing-masing algoritma dan arsitektur

Algoritma	Model	Iterasi	Waktu	Fungsi	MSE Training	MSE Testing
Cyclical Rule (trainc)	4-4-1	2000	00.26	tansig, purelin	0,00051113	0,13400869
	4-5-1	2000	00.23		0,00015745	0,10447841
	4-8-1	63	00.01		0,00009778	0,36139732
	4-10-1	714	00.08		0,00009992	0,13700787
	4-12-1	151	00.02		0,00009862	0,06642131
	4-15-1	985	00.13		0,00009980	0,02638939
	4-16-1	2000	00.27		0,00012877	0,30913154
	4-20-1	1082	00.14		0,00010039	0,02188269
	4-24-1	2000	00.27		0,00023334	0,31702260
	4-25-1	2000	00.27		0,00021162	0,21807218
Bayesian Regulation (trainbr)	4-4-1	1291	00.06	tansig, logsig	0,00000001	0,00904016
	4-5-1	1299	00.06		0,00000001	0,00863179
	4-8-1	376	00.02		0,00000003	0,01134779
	4-10-1	885	00.05		0,00000001	0,00786961
	4-12-1	468	00.03		0,00000004	0,01137614
	4-15-1	465	00.03		0,00000004	0,01138198
	4-16-1	547	00.03		0,00000004	0,01138650
	4-20-1	602	00.04		0,00000004	0,01139234
	4-24-1	746	00.05		0,00000004	0,01139991
	4-25-1	665	00.05		0,00000004	0,01140443

Berdasarkan data yang tersaji pada Tabel 9 dan Gambar 10, dapat dijelaskan bahwa nilai rata-rata kuadrat kesalahan / Mean Square Error (MSE) data training dan data testing dari masing-masing 10 arsitektur yang digunakan menggunakan algoritma Bayesian Regulation (trainbr) lebih optimal dibandingkan algoritma Cyclical Rule (trainc). MSE Testing dari arsitektur 4-10-1 menggunakan algoritma Bayesian Regulation (trainbr) lebih rendah dibandingkan arsitektur 4-4-1, 4-5-1, 4-8-1, 4-12-1, 4-15-1, 4-16-1, 4-20-1, 4-24-1, dan 4-25-1, dengan nilai MSE Testing sebesar 0,00786961. Sebagaimana perlu diketahui, bahwa semakin rendah nilai kesalahan maka hasilnya semakin baik. Sehingga disimpulkan bahwa arsitektur 4-10-1 pada algoritma Bayesian Regulation (trainbr), terpilih sebagai arsitektur yang terbaik dibandingkan dengan arsitektur yang lain. Berdasarkan arsitektur ini akan dilakukan prediksi jumlah kunjungan wisatawan mancanegara (Negara ASEAN) untuk membantu memberikan informasi agar pihak terkait memaksimalkan perencanaan dan pengembangan pariwisata yang lebih efektif.



Gambar 10. Perbandingan MSE Testing

3.4 Prediksi

Prediksi akan dihitung berdasarkan arsitektur terbaik (4-10-1) dengan menggunakan rumus persamaan (5) berikut ini [37]–[40].

$$\text{Prediksi} = \frac{(x-0,1)(b-a)}{0,8} + a \tag{5}$$

Dimana : x merupakan target yang akan di prediksi, a merupakan data terendah berdasarkan dataset penelitian, b merupakan data tertinggi berdasarkan dataset penelitian, 0.1 dan 0.8 merupakan nilai default untuk melakukan prediksi.

Tabel 10. Hasil Prediksi Jumlah Kunjungan Wisatawan Mancanegara (Negara ASEAN)

Kebangsaan	Data Sebelumnya / Tahun						Prediksi
	2017	2018	2019	2020	2021	2022	2023
Brunei Darussalam	23.455	17.279	19.278	2.701	144	4.798	15.668
Malaysia	2.121.888	2.503.344	2.980.753	980.118	480.723	1.212.574	496.212
Philippines	308.977	217.874	260.980	50.413	9.375	78.436	38.012
Singapore	1.554.119	1.768.744	1.934.445	280.492	18.704	736.797	303.270
Thailand	138.235	124.153	136.699	21.303	3.992	61.128	26.689
Vietnam	77.466	75.816	96.024	19.608	2.008	68.067	22.160
Myanmar	48.133	28.612	46.381	12.669	3.093	22.637	17.480
Asean Lainnya	252.373	717.508	682.630	154.143	10.187	223.661	94.928
Total ASEAN	4.524.646	5.453.330	6.157.190	1.521.447	528.226	2.408.098	1.014.418

Berdasarkan Tabel 10 dapat dilihat perbedaan antara data jumlah kunjungan wisatawan mancanegara dari negara-negara ASEAN sebelumnya (tahun 2017 hingga tahun 2022) dan data prediksi tahun 2023. Hasil nya di prediksi pada tahun 2023 kemungkinan terjadi penurunan jumlah kunjungan wisatawan dibandingkan dengan tahun 2022. Tolak ukur prediksi ini diperoleh dari jumlah kunjungan wisatawan pada tahun-tahun sebelumnya.

4. KESIMPULAN

Penggunaan model Jaringan Saraf Tiruan (JST) dan menerapkan algoritma Cyclical Rule dengan optimalisasi algoritma Bayesian Regulation, hasil analisis menunjukkan bahwa model dengan arsitektur 4-10-1 memiliki performa terbaik dalam memprediksi kunjungan wisatawan mancanegara dari negara-negara ASEAN. Model ini berhasil mencapai nilai Mean Squared Error (MSE) pengujian sebesar 0,00786961, yang merupakan yang terendah dibandingkan dengan model-model lain yang diuji. Berdasarkan hasil prediksi kunjungan wisatawan mancanegara dari negara-negara ASEAN pada tahun 2023 mengindikasikan kemungkinan penurunan kunjungan dibandingkan dengan tahun 2022. Hasil prediksi ini memberikan informasi penting bagi para pelaku pariwisata untuk mengambil langkah-langkah strategis guna mengatasi penurunan ini, dengan memanfaatkan prediksi ini, pelaku pariwisata dapat meningkatkan kualitas layanan yang disediakan kepada wisatawan, menyesuaikan kebutuhan wisatawan dengan sumber daya yang tersedia di destinasi, serta mengoptimalkan penggunaan anggaran. Kesimpulan ini menggarisbawahi pentingnya penggunaan model prediksi dalam perencanaan strategis pariwisata. Informasi akurat mengenai prediksi kunjungan wisatawan membantu pemerintah dan pemangku kepentingan untuk mengambil keputusan yang tepat, seperti alokasi anggaran yang efisien, pengembangan infrastruktur yang sesuai, dan penyusunan kebijakan yang relevan. Meskipun prediksi menunjukkan penurunan kunjungan wisatawan, hal



ini dapat menjadi dasar bagi upaya lebih lanjut dalam mengatasi tantangan yang mungkin timbul dalam industri pariwisata di masa mendatang.

UCAPAN TERIMAKASIH

Terima kasih yang sebesar-besarnya kami ucapkan kepada Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi Direktorat Jenderal Pendidikan Tinggi, Riset, dan Teknologi, atas pendanaan Penelitian Dosen Pemula (PDP) tahun pelaksanaan 2023.

REFERENCES

- [1] I. Murapi, D. Ayu, O. Astarini, U. Bumigora, dan S. Pariwisata, "Potensi Sektor Pariwisata sebagai Strategi Pemulihan Ekonomi Provinsi NTB," *Riset Ekonomi, Akuntansi dan Perpajakan*, vol. 3, no. 1, hal. 43–54, 2022, doi: 10.30812/rekan.v3i1.1844.
- [2] A. S. Sitanggang, D. S. Yusuf, M. A. Aridho, S. Wijaya, R. T. Bimantara, dan S. Yuda, "Penggunaan E-Tourism Sebagai Strategi Mempromosikan Pariwisata di Majalengka," *Altasia : Jurnal Pariwisata Indonesia*, vol. 4, no. 2, hal. 52–60, 2022, doi: <http://dx.doi.org/10.37253/altasia.v4i2.6782>.
- [3] I. A. dwi Pratiwi, M. I. Fasa, dan Suharto, "Perspektif Ekonomi Islam Terhadap Pariwisata Halal Di Era," *Youth & Islamic Economic Journal*, vol. 03, no. 01, hal. 14–27, 2022, [Daring]. Tersedia pada: <http://jurnalhamfara.ac.id/index.php/yie/article/view/150>
- [4] V. S. D. Soedarwo, I. R. Fuadiputra, M. R. Bustami, dan G. K. Jha, "Participatory Action Research (PAR) Model for Developing A Tourism Village in Indonesia," *Journal of Local Government Issues*, vol. 5, no. 2, hal. 193–206, 2022, doi: 10.22219/logos.v5i2.21279.
- [5] Suwarni, U. L. S. Khadijah, dan H. Rachmat, "The Development Strategy of Educational Tourism At Rumah Atsiri Indonesia In The Era of Adapting to A New Normal," *Sosiohumaniora: Jurnal Ilmu-ilmu Sosial dan Humaniora*, vol. 23, no. 1, hal. 97–106, 2021, doi: 10.24198/sosiohumaniora.v23i1.31668.
- [6] M. S. Sholehuddin, "Islamic T radition And Religious Culture in Halal T ourism : Empirical Evidence from Indonesia," *IBDA' : Jurnal Kajian Islam dan Budaya*, vol. 19, no. 1, hal. 79–100, 2021, doi: 10.24090/ibda.v19i1.4470.
- [7] S. Wahyuni dan Rahmawati, "Point of View Research Economic Development Analysis of the Potential Sharia Tourism in West Nusa Tenggara," *Point of View Research Economic Development*, vol. 2, no. 2, hal. 59–67, 2021, [Daring]. Tersedia pada: <http://www.journal.accountingpointofview.id/index.php/POVRED/article/view/165>
- [8] J. Sosial, I. Ayu, M. Sri, I. N. D. Astawa, I. Bagus, dan N. Mantra, "The Roles of English in the Development of Tourism and Economy in Indonesia," *SOSHUM : Jurnal Sosial dan Humaniora*, vol. 11, no. 3, hal. 305–313, 2021, doi: <https://doi.org/10.31940/soshum.v11i3.305-313>.
- [9] S. Mouloudi, H. Rahmanpanah, S. Gohari, C. Burvill, K. Ming, dan H. M. S. Davies, "Journal of the Mechanical Behavior of Biomedical Materials What can artificial intelligence and machine learning tell us ? A review of applications to equine biomechanical research," *Journal of the Mechanical Behavior of Biomedical Materials*, vol. 123, hal. 104728, 2021, doi: 10.1016/j.jmbbm.2021.104728.
- [10] P. Singh, P. Dimri, P. Gupta, dan G. P. Saroha, "Resource provisioning in scalable cloud using bio-inspired artificial neural network model," *Applied Soft Computing Journal*, vol. 99, hal. 106876, 2021, doi: 10.1016/j.asoc.2020.106876.
- [11] M. Dobarjeh dkk., "Personalised predictive modelling with brain-inspired spiking neural networks of longitudinal MRI neuroimaging data and the case study of dementia," *Neural Networks*, vol. 144, hal. 522–539, 2021, doi: 10.1016/j.neunet.2021.09.013.
- [12] A. Kontogianni, E. Alepis, dan C. Patsakis, "Promoting smart tourism personalised services via a combination of deep learning techniques," *Expert Systems with Applications*, vol. 187, no. October 2021, hal. 115964, 2022, doi: 10.1016/j.eswa.2021.115964.
- [13] K. Kaya, Y. Yılmaz, Y. Yaslan, Ş. G. Ögüdücü, dan F. Çingı, "Demand forecasting model using hotel clustering findings for hospitality industry," *Information Processing and Management*, vol. 59, no. 1, hal. 102816, 2022, doi: 10.1016/j.ipm.2021.102816.
- [14] A. Kulshrestha, V. Krishnaswamy, dan M. Sharma, "Bayesian BILSTM approach for tourism demand forecasting," *Annals of Tourism Research*, vol. 83, hal. 102925, 2020, doi: 10.1016/j.annals.2020.102925.
- [15] G. Xie, Y. Qian, dan S. Wang, "Forecasting Chinese cruise tourism demand with big data: An optimized machine learning approach," *Tourism Management*, vol. 82, hal. 104208, 2021, doi: 10.1016/j.tourman.2020.104208.
- [16] G. Li, D. C. Wu, M. Zhou, dan A. Liu, "The combination of interval forecasts in tourism," *Annals of Tourism Research*, vol. 75, hal. 363–378, 2019, doi: 10.1016/j.annals.2019.01.010.
- [17] C. Zhang, S. Wang, S. Sun, dan Y. Wei, "Knowledge mapping of tourism demand forecasting research," *Tourism Management Perspectives*, vol. 35, no. 28, hal. 100715, 2020, doi: 10.1016/j.tmp.2020.100715.
- [18] M. Cuhadar, "Modelling and Forecasting Inbound Tourism Demand to Croatia using Artificial Neural Networks: A Comparative Study," *Journal of Tourism and Services*, vol. 11, no. 21, hal. 55–70, 2020, doi: 10.29036/jots.v11i21.171.
- [19] S. M. Chen, D. J. Bauer, W. M. Belzak, dan H. Brandt, "Advantages of Spike and Slab Priors for Detecting Differential Item Functioning Relative to Other Bayesian Regularizing Priors and Frequentist Lasso," *Structural Equation Modeling*, vol. 29, no. 1, hal. 122–139, 2022, doi: 10.1080/10705511.2021.1948335.
- [20] BPS, "Jumlah Kunjungan Wisatawan Mancanegara ke Indonesia Menurut Kebangsaan (Kunjungan)," *Publikasi Statistik Indonesia*, 2023. <https://www.bps.go.id/indicator/16/1821/1/jumlah-kunjungan-wisatawan-mancanegara-ke-indonesia-menurut-kebangsaan.html> (diakses 15 Juni 2023).
- [21] M. Hu, H. Li, H. Song, X. Li, dan R. Law, "Tourism demand forecasting using tourist-generated online review data," *Tourism Management*, vol. 90, no. January, hal. 104490, 2022, doi: 10.1016/j.tourman.2022.104490.
- [22] R. Ye dan Q. Dai, "A relationship-aligned transfer learning algorithm for time series forecasting," *Information Sciences*,



- vol. 593, hal. 17–34, 2022, doi: 10.1016/j.ins.2022.01.071.
- [23] W. Wei dan J. Chuan, “A combination forecasting method of grey neural network based on genetic algorithm,” *Procedia CIRP*, vol. 109, hal. 191–196, 2022, doi: 10.1016/j.procir.2022.05.235.
- [24] S. Sun, Z. Du, C. Zhang, dan S. Wang, “Improving multi-step ahead tourism demand forecasting: A strategy-driven approach,” *Expert Systems with Applications*, vol. 210, no. April, hal. 118465, 2022, doi: 10.1016/j.eswa.2022.118465.
- [25] K. He, L. Ji, C. W. D. Wu, dan K. F. G. Tso, “Using SARIMA–CNN–LSTM approach to forecast daily tourism demand,” *Journal of Hospitality and Tourism Management*, vol. 49, no. September, hal. 25–33, 2021, doi: 10.1016/j.jhtm.2021.08.022.
- [26] Y. Dong, L. Xiao, J. Wang, dan J. Wang, “A time series attention mechanism based model for tourism demand forecasting,” *Information Sciences*, vol. 628, no. January, hal. 269–290, 2023, doi: 10.1016/j.ins.2023.01.095.
- [27] F. Mu’minin dan A. Gunaryati, “Prediksi Kunjungan Wisatawan Mancanegara Melalui Pintu Udara Menggunakan ARIMA, Glnet, dan Prophet,” *Februari*, vol. 21, no. 1, hal. 149–156, 2022, doi: 10.33633/tc.v21i1.5695.
- [28] H. Mukhtar, R. Gunawan, A. Hariyanto, Syahril, dan Wide Mulyana, “Peramalan Kedatangan Wisatawan ke Suatu Negara Menggunakan Metode Support Vector Machine (SVM),” *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 3, no. 3, hal. 274–282, 2022, doi: 10.37859/coscitech.v3i3.4211.
- [29] M. A. Ridla, N. Azise, dan M. Rahman, “Perbandingan Model Time Series Forecasting Dalam Memprediksi Jumlah Kedatangan Wisatawan Dan Penumpang Airport,” *Jurnal Sistem Informasi dan Sistem Komputer*, vol. 8, no. 1, hal. 1–14, 2023, doi: 10.51717/simkom.v8i1.103.
- [30] F. Riestiansyah, D. Damayanti, M. Reswara, dan R. Susetyoko, “Perbandingan metode ARIMA dan ARIMAX dalam Memprediksi Jumlah Wisatawan Nusantara di Pulau Bali,” *Jurnal Infomedia: Teknik Informatika, Multimedia & Jaringan*, vol. 7, no. 2, hal. 58–62, 2022, doi: 10.30811/jim.v7i2.3336.
- [31] F. Fatimatuzzahra, R. Hammad, A. Z. Amrullah, dan P. Irfan, “Optimasi Neural Network Dengan Menggunakan Algoritma Genetika Untuk Prediksi Jumlah Kunjungan Wisatawan,” *JTIM : Jurnal Teknologi Informasi dan Multimedia*, vol. 3, no. 4, hal. 227–235, 2022, doi: 10.35746/jtim.v3i4.190.
- [32] W. Saputra dkk., “Implementation of ANN for Predicting the Percentage of Illiteracy in Indonesia by Age Group,” *Journal of Physics: Conference Series*, vol. 1255, no. 012043, hal. 1–6, 2019, doi: 10.1088/1742-6596/1255/1/012043.
- [33] M. K. Z. Sormin, P. Sihombing, A. Amalia, A. Wanto, D. Hartama, dan D. M. Chan, “Predictions of World Population Life Expectancy Using Cyclical Order Weight / Bias,” *Journal of Physics: Conference Series*, vol. 1255, no. 012017, hal. 1–6, 2019, doi: 10.1088/1742-6596/1255/1/012017.
- [34] S. Setti dan A. Wanto, “Analysis of Backpropagation Algorithm in Predicting the Most Number of Internet Users in the World,” *JOIN (Jurnal Online Informatika)*, vol. 3, no. 2, hal. 110–115, 2018, doi: 10.15575/join.
- [35] A. Wanto, S. Defit, dan A. P. Windarto, “Algoritma Fungsi Pelatihan pada Machine Learning berbasis ANN untuk Peramalan Fenomena Bencana,” *RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, hal. 254–264, 2021, doi: <https://doi.org/10.29207/resti.v5i2.3031>.
- [36] M. O. Shabani dan A. Mazahery, “Prediction Performance of Various Numerical Model Training Algorithms in Solidification Process of A356 Matrix Composites,” *Indian Journal of Engineering and Materials Sciences*, vol. 19, no. 2, hal. 129–134, 2012, [Daring]. Tersedia pada: <file:///WOS:000305550200006>
- [37] M. Julham, S. Sumarno, F. Anggraini, A. Wanto, dan S. Solikhun, “Penerapan Jaringan Syaraf Tiruan dalam Memprediksi Tingkat Kriminal di Kabupaten Simalungun Menggunakan Algoritma Backpropagation,” *BRAHMANA: Jurnal Penerapan Kecerdasan Buatan*, vol. 1, no. 1, hal. 64–73, 2019, doi: 10.30645/brahmana.v1i1.9.
- [38] N. Z. Purba, A. Wanto, dan I. O. Kirana, “Implementation of ANN for Prediction of Unemployment Rate Based on Urban Village in 3 Sub-Districts of Pematangsiantar,” *International Journal of Information System & Technology*, vol. 3, no. 1, hal. 107–116, 2019.
- [39] I. C. Saragih, D. Hartama, dan A. Wanto, “Prediksi Perkembangan Jumlah Pelanggan Listrik Menurut Pelanggan Area Menggunakan Algoritma Backpropagation,” *Building of Informatics, Technology and Science (BITS)*, vol. 2, no. 1, hal. 48–54, 2020.
- [40] M. Syafiq, D. Hartama, I. O. Kirana, I. Gunawan, dan A. Wanto, “Prediksi Jumlah Penjualan Produk di PT Ramayana Pematangsiantar Menggunakan Metode JST Backpropagation,” *JURIKOM (Jurnal Riset Komputer)*, vol. 7, no. 1, hal. 175, 2020, doi: 10.30865/jurikom.v7i1.1963.