

Forecasting Export Values in West Sumatra Using Backpropagation Neural Network

Desi Rahmawati^{1*}, Zamahsary Martha^{2*}

* Statistika, Universitas Negeri Padang

deeesiiiiy@gmail.com¹, zamahsarymartha@fmipa.unp.ac.id²

Article Info

Article history:

Received 2026-01-07

Revised 2026-01-26

Accepted 2026-01-30

Keyword:

*Backpropagation Neural Network (BPNN),
Export Forecasting,
West Sumatra,
Time Series.*

ABSTRACT

Export value is an important indicator in supporting regional economic growth. However, its movement tends to be volatile and non-linear, making it difficult to forecast using conventional statistical methods such as ARIMA. This study aims to forecast the export value of West Sumatra Province using an Artificial Neural Network (ANN) with the Backpropagation algorithm. The data used consist of monthly export values from January 2006 to October 2025 obtained from Badan Pusat Statistik (BPS) of West Sumatra Province. The data were normalized and modified using the rolling window method, then divided into training and testing datasets. Several network architectures were evaluated through a trial-and-error process with variations in the number of neurons in the hidden layer. The best model was achieved with the BPNN(12,12,1) architecture, yielding a Mean Square Error (MSE) of 0.0236 and a Mean Absolute Percentage Error (MAPE) of 25.31%. The results indicate that the model is capable of capturing non-linear patterns and reasonably following the trend of the actual data. The selected model was then used to perform short-term forecasting of export values for the period from November 2025 to March 2026. The findings demonstrate that the Backpropagation Neural Network algorithm is effective for forecasting export values in West Sumatra Province. This study contributes theoretically by enriching the application of artificial intelligence in regional economic forecasting and practically by supporting data-driven policy formulation for export strategies in West Sumatra.



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

I. PENDAHULUAN

Ekspor merupakan salah satu motor utama penggerak pertumbuhan ekonomi, baik di tingkat nasional maupun daerah. Kontribusi ekspor tidak hanya meningkatkan devisa, tetapi juga mendorong penciptaan lapangan kerja, diversifikasi ekonomi, serta memperkuat daya saing di pasar global [1]. Provinsi Sumatera Barat, yang didominasi oleh ekspor komoditas unggulan seperti lemak dan minyak nabati (CPO) serta karet, merupakan salah satu kontributor penting ekspor nonmigas Indonesia. Namun, kinerja ekspor daerah ini menunjukkan volatilitas yang tinggi dari waktu ke waktu. Ketergantungan pada dinamika harga komoditas global dan perubahan kebijakan perdagangan internasional menyebabkan nilai ekspor Provinsi Sumatera Barat sangat rentan terhadap gejolak eksternal. Pola pergerakan yang non-

linear ini tampak jelas bahkan dalam interval waktu yang relatif singkat. Badan Pusat Statistik mencatat nilai ekspor Provinsi Sumatera Barat mencapai US\$ 305,49 juta pada Juli 2022, turun drastis menjadi US\$ 196,12 juta pada September 2022, kemudian kembali meningkat menjadi US\$ 274,72 juta pada Oktober 2022 [2]. Ketidakstabilan yang kompleks dan bersifat non-linear tersebut menimbulkan tantangan signifikan dalam perumusan kebijakan ekonomi dan strategi ekspor yang efektif, sehingga diperlukan model peramalan yang lebih adaptif dan mampu menangkap pola data dinamis.

Fluktuasi ekspor sering dipengaruhi oleh harga komoditas global, perubahan kurs, permintaan negara mitra, hingga kebijakan perdagangan internasional [3]. Dalam konteks Provinsi Sumatera Barat, dominasi beberapa komoditas utama menyebabkan nilai ekspor sangat rentan terhadap

gejolak harga di pasar dunia. Oleh sebab itu, metode peramalan yang akurat diperlukan agar pemangku kepentingan dapat mengantisipasi risiko dan merumuskan strategi adaptif untuk menjaga stabilitas ekonomi daerah.

Peramalan merupakan salah satu pendekatan analisis data historis untuk memperkirakan nilai di masa depan. Metode tradisional seperti *Autoregressive Integrated Moving Average* (ARIMA) telah lama digunakan untuk meramalkan data runtun waktu ekonomi, termasuk ekspor [4]. Studi mengenai peramalan ekspor Provinsi Sumatera Barat menggunakan ARIMA menunjukkan bahwa model tersebut dapat memberikan hasil yang cukup baik dalam menangkap pola tren jangka pendek [5]. Namun, ARIMA memiliki keterbatasan dalam menghadapi pola non-linear, musiman kompleks, serta pengaruh variabel eksternal [6]. Keterbatasan model linear seperti ARIMA dalam menangkap dinamika non-linear menjadi alasan utama berkembangnya pendekatan berbasis neural network untuk analisis ekonomi makro dan peramalan perdagangan [7].

Seiring kemajuan teknologi, metode berbasis kecerdasan buatan, khususnya jaringan saraf tiruan, mulai banyak diterapkan karena kemampuannya dalam menangkap hubungan non-linear pada data ekonomi yang kompleks [8]. Metode berbasis machine learning seperti *Gated Recurrent Unit* (GRU) dan *Long Short-Term Memory* (LSTM) telah menunjukkan performa yang menjanjikan dalam mengenali pola jangka panjang [9, 10]. Namun, model *recurrent neural network* (RNN) tersebut memerlukan volume data besar dan sumber daya komputasi yang tinggi, sehingga penerapannya pada skala provinsi dengan jumlah data terbatas kurang efisien [11].

Dalam konteks ini, *backpropagation neural network* (BPNN) menjadi alternatif yang lebih sederhana dan efisien, namun tetap mampu mengenali pola non-linear dengan akurasi yang baik. BPNN, sebagai salah satu algoritma utama dalam jaringan saraf tiruan, telah terbukti efektif dalam mereduksi error prediksi dan meningkatkan akurasi di berbagai bidang ekonomi [12]. Model jaringan saraf tiruan berbasis backpropagation yang diuji pada data ekspor CPO Indonesia menunjukkan performa prediksi yang baik, ditandai dengan MAPE pelatihan hanya 23,7%, sehingga metode ini dapat digunakan sebagai pendekatan yang efektif untuk meramalkan data ekspor [13].

Pendekatan *hybrid neural network* yang menggabungkan jaringan saraf tiruan dengan arsitektur pembelajaran tambahan juga telah terbukti efektif dalam meningkatkan akurasi dan stabilitas prediksi pada data ekspor dan impor yang kompleks. Metode ini mampu mengidentifikasi pola non-linear serta mengolah data berskala besar dengan struktur yang beragam, seperti yang ditunjukkan melalui penerapan *Hybrid Convolutional Neural Network* dengan *Auxiliary Network* pada klasifikasi komoditas ekspor-impor [14]. Namun, model tersebut umumnya dirancang untuk lingkungan dengan ketersediaan data yang besar dan terstruktur, sedangkan pada konteks daerah seperti tingkat provinsi, volume data ekspor yang terbatas dapat menjadi

kendala dalam penerapan model yang kompleks. Oleh sebab itu, penelitian ini memfokuskan pada penggunaan BPNN yang lebih sederhana dan efisien, namun tetap mampu mengenali pola non-linear, sehingga lebih sesuai untuk karakteristik data ekspor Provinsi Sumatera Barat yang berskala menengah dan fluktuatif. Selain itu, penerapan model kecerdasan buatan dalam konteks ekonomi regional terbukti mampu meningkatkan ketepatan kebijakan berbasis data dan mendukung perencanaan pembangunan daerah [15]. Oleh karena itu, penelitian ini menyoroti penerapan BPNN secara spesifik untuk peramalan nilai ekspor bulanan Provinsi Sumatera Barat periode Januari 2006 hingga Oktober 2025 guna mengisi kesenjangan dalam literatur lokal serta memberikan model peramalan yang adaptif dan aplikatif bagi pemangku kebijakan daerah.

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk meramalkan nilai ekspor Provinsi Sumatera Barat dengan BPNN menggunakan data bulanan periode Januari 2006 hingga Oktober 2025. Diharapkan, penelitian ini dapat memberikan kontribusi teoritis berupa pengayaan literatur forecasting ekonomi regional dengan pendekatan AI, serta kontribusi praktis bagi pemerintah daerah dan pelaku usaha dalam menyusun kebijakan dan strategi ekspor yang berbasis data serta adaptif terhadap dinamika pasar global.

II. METODE

Jenis data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari situs resmi <http://www.sumbar.bps.go.id/>. Data yang digunakan adalah data nilai ekspor dari Januari 2006 hingga Oktober 2025, dengan jumlah observasi sebanyak 238 dengan satuan data dalam juta US Dollar. Data dalam penelitian ini merupakan data deret waktu yang berisi nilai-nilai variabel berdasarkan interval waktu bulanan dan berbentuk numerik. Metode yang digunakan dalam penelitian ini adalah metode jaringan saraf tiruan berbasis algoritma backpropagation.

Menganalisis jaringan saraf tiruan berbasis algoritma backpropagation memerlukan beberapa tahapan [16]. Pemilihan parameter seperti *learning rate*, jumlah neuron tersembunyi, dan jumlah iterasi berperan penting dalam menentukan kinerja dan akurasi model jaringan saraf tiruan [17].

- 1) Melakukan proses normalisasi data agar data input dan output berada pada rentang nilai 0 sampai 1. Rumus yang digunakan adalah sebagai berikut

$$z = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$$

- 2) Inisialisasi bobot, tetapkan target error, jumlah epoch maksimum, dan *learning rate* (α).
- 3) Melakukan fase propagasi maju
 - a. Setiap unit pada lapisan input ($x_i, i = 1, \dots, n$) menerima sinyal input x_i dan diteruskan ke unit-

unit tersembunyi. Setiap unit tersembunyi ($z_j, j = 1, \dots, p$) menjumlahkan sinyal input terbobot.

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij}$$

Keterangan:

z_{in_j} : jumlah sinyal neuron lapisan input yang menuju ke neuron lapisan tersembunyi ke-j ($j = 1, 2, 3, \dots, p$)

v_{0j} : bobot yang menghubungkan neuron bias lapisan input dengan neuron lapisan tersembunyi ke-j ($j = 1, 2, 3, \dots, p$)

v_{ij} : bobot yang menghubungkan neuron ke-i dari lapisan input ($i = 1, 2, 3, \dots, i$) dengan neuron ke-j dari lapisan tersembunyi ($j = 1, 2, 3, \dots, p$)

x_i : nilai neuron ke-i pada lapisan input ($i = 1, 2, 3, \dots, n$)

n : jumlah neuron pada lapisan input

Dengan menerapkan fungsi aktivasi, hitung:

$$z_j = f(z_{in_j}) = \frac{1}{1 + e^{-z_{in_j}}}$$

- b. Kemudian, kirim sinyal ini ke unit-unit output. Setiap unit output ($y_k, k = 1, \dots, m$) menjumlahkan sinyal input terbobot.

$$y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk}$$

Keterangan:

y_{in_k} : jumlah sinyal neuron lapisan tersembunyi yang menuju ke neuron lapisan keluaran ke-k ($k = 1, 2, 3, \dots, m$)

w_{0k} : bobot yang menghubungkan neuron bias lapisan tersembunyi dengan neuron lapisan keluaran ke-k ($k = 1, 2, 3, \dots, m$)

w_{jk} : bobot yang menghubungkan neuron lapisan tersembunyi ke-j ($j = 1, 2, 3, \dots, p$) dengan neuron lapisan keluaran ke-k ($k = 1, 2, 3, \dots, m$)

z_j : nilai neuron lapisan tersembunyi ke-j ($j = 1, 2, 3, \dots, p$)

p : jumlah neuron pada lapisan tersembunyi

Dengan menerapkan fungsi aktivasi, hitung:

$$y_k = f(y_{in_k}) = \frac{1}{1 + e^{-y_{in_k}}}$$

4) Melakukan fase propagasi mundur

- a. Setiap unit output ($y_k, k = 1, \dots, m$) menerima target (output yang diharapkan) dibandingkan dengan output yang dihasilkan. Hitung galat (error):

$$\delta_k = (t_k - y_k) f'(y_{in_k})$$

Keterangan:

δ_k : nilai faktor kesalahan pada neuron lapisan keluaran ke-k

t_k : nilai data actual pada waktu ke-k

y_k : nilai dari lapisan keluaran pada waktu ke-k
 y_{in_k} : jumlah sinyal neuron lapisan tersembunyi yang masuk ke neuron lapisan keluaran ke-k ($k = 1, 2, 3, \dots, m$)

Hitung koreksi bobot dan biasnya:

$$\Delta w_{jk} = \alpha \delta_k z_j$$

$$\Delta w_{0k} = \alpha \delta_k$$

Keterangan:

Δw_{jk} : koreksi bobot antara neuron lapisan tersembunyi ke-j dan neuron lapisan keluaran ke-k.

Δw_{0k} : koreksi bobot bias antara neuron tersembunyi ke-j dan neuron lapisan keluaran ke-k

α : koefisien laju pembelajaran (*learning rate*)

δ_k : nilai faktor kesalahan dari neuron lapisan keluaran ke-k

z_j : nilai dari neuron lapisan tersembunyi ke-j ($j = 1, 2, 3, \dots, p$)

- b. Untuk setiap unit tersembunyi ($z_j, j = 1, \dots, p$) menjumlahkan delta inputannya (dari unit-unit di lapisan atasnya).

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk}$$

Keterangan:

δ_{in_j} : jumlah faktor kesalahan pada neuron lapisan tersembunyi ke-j

δ_k : nilai faktor kesalahan pada neuron lapisan keluaran ke-k

w_{jk} : bobot yang menghubungkan neuron lapisan tersembunyi ke-j ($j = 1, 2, 3, \dots, p$) ke neuron lapisan keluaran ke-k ($k = 1, 2, 3, \dots, m$).

Hitung galat (error):

$$\delta_j = \delta_{in_j} f'(z_{in_j})$$

Keterangan:

δ_j : nilai faktor kesalahan pada neuron lapisan tersembunyi ke-j

δ_{in_j} : jumlah faktor kesalahan pada neuron lapisan tersembunyi ke-j

z_{in_j} : jumlah sinyal neuron lapisan input yang masuk ke neuron lapisan tersembunyi ke-j ($j = 1, 2, 3, \dots, p$)

Hitung koreksi bobot dan biasnya:

$$\Delta v_{ij} = \alpha \delta_j x_i$$

$$\Delta v_{0j} = \alpha \delta_j$$

Keterangan:

Δv_{ij} : koreksi bobot antara neuron lapisan tersembunyi ke-i dan neuron lapisan tersembunyi ke-j.

Δv_{0j} : koreksi bobot bias antara neuron tersembunyi ke-i dan neuron lapisan tersembunyi ke-j
 α : koefisien laju pembelajaran (*learning rate*)
 δ_j : nilai faktor kesalahan pada neuron lapisan tersembunyi ke-j
 x_i : nilai dari neuron lapisan input ke-i ($i = 1, 2, 3, \dots, n$)

5) Melakukan fase perubahan bobot

- a. Setiap unit output (y_k , $k = 1, \dots, m$) memperbaharui bobot-bobot dan biasnya ($j = 0, 1, \dots, p$)

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk}$$

$$w_{0k}(\text{baru}) = w_{0k}(\text{lama}) + \Delta w_{0k}$$

- b. Setiap unit tersembunyi (z_j , $j = 1, \dots, p$) memperbaharui bobot dan biasnya ($i = 0, 1, \dots, n$)

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij}$$

$$v_{0j}(\text{baru}) = v_{0j}(\text{lama}) + \Delta v_{0j}$$

Keterangan:

$w_{jk}(\text{baru})$: nilai bobot baru yang menghubungkan neuron lapisan tersembunyi ke-j ke neuron lapisan keluaran ke-k

$w_{jk}(\text{lama})$: nilai bobot lama yang menghubungkan neuron lapisan tersembunyi ke-j ke neuron lapisan keluaran ke-k

$w_{0k}(\text{baru})$: nilai bobot bias baru pada lapisan keluaran ke-k

$w_{0k}(\text{lama})$: nilai bobot bias lama pada lapisan keluaran ke-k

$v_{ij}(\text{baru})$: nilai bobot baru yang menghubungkan neuron ke-i pada lapisan input dengan neuron ke-j pada lapisan tersembunyi

$v_{ij}(\text{lama})$: nilai bobot lama yang menghubungkan neuron ke-i pada lapisan input dengan neuron ke-j pada lapisan tersembunyi

$v_{0j}(\text{baru})$: nilai bobot bias baru pada lapisan tersembunyi ke-j

$v_{0j}(\text{lama})$: nilai bobot bias lama pada lapisan tersembunyi ke-j

- 6) Periksa kondisi penghentian. Ketika kondisi berhenti terpenuhi, pelatihan jaringan dapat dihentikan. Ada dua cara umum untuk menentukan kondisi penghentian, yaitu

- a. Batasi jumlah iterasi yang akan dilakukan.
 a) Misalkan jaringan dilatih hingga iterasi ke-500
 b) Iterasi mengulangi langkah 3 sampai 5 untuk semua data pelatihan yang tersedia.
 b. Membatasi kesalahan
 Sebagai contoh, tentukan *mean square error* antara output yang diinginkan dengan output yang dihasilkan oleh jaringan.

Keterangan:

$x_1 \dots x_n$: input

$y_1 \dots y_m$: output

$z_1 \dots z_p$: nilai lapisan tersembunyi

v_{ij} : bobot antara lapisan input dan lapisan tersembunyi

w_{jk} : bobot antara lapisan tersembunyi dan lapisan output

δ : nilai faktor kesalahan/galat (error)

α : koefisien laju pembelajaran (*learning rate*)

III. HASIL DAN PEMBAHASAN

Sebelum melakukan analisis terhadap data nilai ekspor, perlu dilakukan eksplorasi data terlebih dahulu. Eksplorasi data dilakukan untuk melihat karakteristik atau gambaran umum data nilai ekspor pada periode Januari 2006 hingga Oktober 2025 secara umum dapat dilihat pada Tabel 1.

TABEL I
EKSPLORASI DATA NILAI EKSPOR

Variabel	N	Mean	Minimum	Maksimum
Nilai ekspor	238	172,80	0,62	392,81

Tabel 1 menunjukkan bahwa data yang digunakan hanya terdiri dari satu variabel, yaitu data nilai ekspor. Data nilai ekspor terdiri dari 238 observasi, dengan nilai ekspor terendah sebesar 0,62 juta US Dollar dan tertinggi sebesar 392,81 juta US Dollar.

Sebelum proses analisis data, dilakukan proses normalisasi data. Salah satu tujuan dari normalisasi adalah untuk membuat data yang digunakan stabil, karena data dengan rentang nilai yang lebih lebar dapat menyebabkan ketidakstabilan pada perhitungan numerik dalam model. Data nilai ekspor dari Januari 2006 hingga Oktober 2025 dinormalisasi sehingga berada pada interval 0 hingga 1. Tabel 2 menunjukkan hasil setelah proses normalisasi data.

TABEL II
NORMALISASI DATA NILAI EKSPOR

Tahun	Bulan ke-					
	1	2	3	...	11	12
2006	0,0758	0,2822	0,1842	...	0,1303	0,2082
2007	0,1959	0,2436	0,2279	...	0,4268	0,7758
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2024	0,3396	0,4049	0,4322	...	0,5600	0,4410
2025	0,3891	0,6922	0,5600	...	-	-

Setelah proses normalisasi dilakukan dan didapatkan hasil seperti pada Tabel 2, data nilai ekspor yang telah dinormalisasi tersebut dimodifikasi dengan menggunakan metode *rolling window*, dan didapatkan hasil seperti data yang telah dimodifikasi pada Tabel 3.

TABEL III
DATA NILAI EKSPOR YANG DIMODIFIKASI

Pola	X ₁	X ₂	X ₃	...	X ₁₂	Target
1	0,0758	0,2822	0,1842	...	0,2082	0,1959
2	0,2822	0,1842	0,2822	...	0,1959	0,2436
3	0,1842	0,2822	0,0904	...	0,2436	0,2279
4	0,2822	0,0904	0,1540	...	0,2279	0,3439
⋮	⋮	⋮	⋮	⋮	⋮	⋮
225	0,3441	0,6201	0,5600	...	0,8113	0,4617
226	0,6201	0,5600	0,4410	...	0,4617	0,6283

Setelah mendapatkan data dengan struktur seperti yang ditunjukkan pada Tabel 3, langkah selanjutnya adalah membagi data menjadi dua bagian, yaitu dibagi menjadi data latih dan data uji secara runtut berdasarkan urutan waktu (*time series split*). Data latih digunakan untuk melatih model BPNN, sedangkan data uji digunakan untuk mengevaluasi kinerja model. Proses evaluasi dilakukan menggunakan nilai *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) pada data uji. Pendekatan ini dipilih untuk menjaga konsistensi temporal data dan menghindari kebocoran informasi pada proses pelatihan dan pengujian model.

Data nilai ekspor yang digunakan dalam penelitian ini dibagi menjadi data latih sebanyak 80% dan data uji sebanyak 20%. Dengan demikian pola 1 hingga 173 digunakan sebagai data latih, sedangkan pola 174 hingga 216 digunakan sebagai data uji. Dalam menjalankan BPNN, ada tiga jaringan yang dibentuk yaitu lapisan *input*, *hidden*, dan *output*. Data yang digunakan sebagai *input layer* adalah variabel X₁ sampai X₁₂. Penggunaan 12 neuron pada lapisan *input* merepresentasikan nilai ekspor selama dua belas bulan sebelumnya. Pendekatan ini dipilih untuk menangkap pola musiman tahunan (*annual seasonality*) yang umum terjadi pada data ekspor, mengingat aktivitas perdagangan internasional sering dipengaruhi oleh siklus permintaan global tahunan [18]. Sementara itu, pemilihan jumlah neuron tersembunyi dilakukan untuk menyeimbangkan kompleksitas model dan kemampuan generalisasi. Jumlah neuron tersembunyi yang terlalu sedikit berpotensi menyebabkan *underfitting*, sedangkan jumlah yang terlalu banyak dapat meningkatkan risiko *overfitting* [7]. Oleh karena itu, arsitektur BPNN dengan jumlah neuron *input layer* dan *hidden layer* sebanyak 12 dipilih sebagai struktur yang paling optimal berdasarkan evaluasi kinerja model pada data uji. Jumlah *hidden layer* yang digunakan tidak terbatas karena tidak ada aturan baku mengenai jumlah ini. Pada kasus ini, digunakan *hidden layer*, dengan 2 sampai 15 neuron. Selanjutnya, model BPNN terbaik ditentukan melalui proses *trial-and-error*. Proses *trial-and-error* dilakukan karena jumlah neuron pada *hidden layer* mempengaruhi nilai ekspor yang dihasilkan. Model BPNN terbaik dipilih berdasarkan nilai MSE dan MAPE terkecil dari proses *trial-and-error*. Namun, proses pelatihan dilakukan sebelum pengujian agar model belajar menyesuaikan bobot dan bias untuk meminimalkan

kesalahan. Tabel 4 menunjukkan model jaringan yang dibentuk oleh metode BPNN pada data uji.

TABEL IV
MODEL TERBAIK


Variabel	Neuron Tersembunyi	MSE	MAPE
BPNN(12,2,1)	2	0,0308	29,20%
BPNN (12,3,1)	3	0,0297	28,14%
BPNN(12,4,1)	4	0,0275	28,63%
BPNN(12,5,1)	5	0,0254	27,51%
BPNN(12,6,1)	6	0,0243	27,76%
BPNN(12,7,1)	7	0,0288	29,50%
BPNN(12,8,1)	8	0,0265	30,01%
BPNN(12,9,1)	9	0,0242	28,54%
BPNN(12,10,1)	10	0,0253	28,18%
BPNN(12,11,1)	11	0,0245	26,66%
BPNN(12,12,1)*	12	0,0236	25,31%
BPNN(12,13,1)	13	0,0236	27,93%
BPNN(12,14,1)	14	0,0242	27,00%
BPNN(12,15,1)	15	0,0232	27,28%

*Model Terbaik

Berdasarkan Tabel 4, terdapat 14 model jaringan saraf tiruan berbasis algoritma backpropagation yang dapat digunakan untuk meramalkan nilai ekspor di Provinsi Sumatera Barat. Namun diantara 14 model yang memenuhi kriteria MSE dan MAPE, model yang paling kecil adalah model BPNN(12,12,1) dengan MSE 0,0236 dan MAPE 25,31%. Sebagai pembandingan terhadap metode peramalan konvensional, hasil penelitian ini dibandingkan secara kuantitatif dengan penelitian sebelumnya yang menggunakan metode ARIMA. Pada penelitian tersebut, metode ARIMA menghasilkan nilai MAPE sebesar 45,4%. Jika dibandingkan dengan hasil tersebut, model BPNN pada penelitian ini menghasilkan tingkat kesalahan yang lebih rendah, yaitu dengan nilai MAPE sebesar 25,31%. Perbedaan ini menunjukkan bahwa model berbasis jaringan saraf tiruan memiliki kemampuan yang lebih baik dalam menangkap pola non-linear dan fluktuasi data ekspor dibandingkan metode linear konvensional seperti ARIMA [19].

Perubahan jumlah neuron pada lapisan tersembunyi tidak selalu menghasilkan penurunan nilai MSE dan MAPE secara konsisten. Hal ini menunjukkan bahwa peningkatan kompleksitas jaringan tidak selalu berbanding lurus dengan peningkatan akurasi model. Model BPNN(12,12,1) dipilih sebagai model terbaik karena menghasilkan nilai MAPE terendah sebesar 25,31% dibandingkan model lainnya, yang mengindikasikan kemampuan prediksi yang relatif lebih baik pada data uji. Hasil ini juga mengonfirmasi bahwa terdapat titik optimal jumlah neuron tersembunyi yang mampu menyeimbangkan kemampuan pembelajaran pola non-linear dan kemampuan generalisasi model. Nilai MAPE sebesar 25,31% menunjukkan tingkat kesalahan prediksi yang tergolong moderat dalam konteks peramalan ekonomi regional. Data nilai ekspor memiliki volatilitas tinggi dan dipengaruhi oleh banyak faktor eksternal yang sulit

dimodelkan secara eksplisit. Beberapa penelitian menyatakan bahwa nilai MAPE pada kisaran 20–30% masih dapat diterima untuk peramalan data ekonomi makro yang bersifat non-linear dan fluktuatif, terutama untuk tujuan perencanaan dan pengambilan keputusan jangka pendek [20,21].



Gambar 1. Grafik perbandingan hasil prediksi data uji dan data aktual

Berdasarkan Gambar 1, dapat dilihat bahwa model BPNN(12,12,1) menunjukkan performa yang cukup baik dalam memprediksi data uji. Hal ini ditunjukkan dengan garis hasil prediksi yang hampir mendekati dan mengikuti pola tren dari data aktual, baik pada fluktuasi maupun arah pergerakan data nilai ekspor. Meskipun terdapat deviasi di beberapa titik, model dapat melakukan generalisasi terhadap data baru. Deviasi ini mencerminkan karakteristik data ekspor yang sangat dipengaruhi oleh faktor eksternal seperti dinamika harga komoditas dan kebijakan perdagangan. Namun demikian, kedekatan pola antara data aktual dan hasil prediksi menunjukkan bahwa model BPNN(12,12,1) memiliki kemampuan generalisasi yang cukup baik dalam menangkap hubungan non-linear pada data nilai ekspor. Berdasarkan model Backpropagation terbaik yang diperoleh dari proses seleksi jumlah neuron tersembunyi dengan kriteria nilai MAPE terkecil pada data pengujian, selanjutnya dilakukan peramalan nilai ekspor untuk periode yang belum memiliki data aktual. Peramalan difokuskan pada jangka pendek, yaitu dua bulan terakhir tahun 2025 serta tiga bulan pertama tahun 2026, dengan mempertimbangkan keterbatasan model berbasis data historis dalam melakukan prediksi jangka panjang. Hasil peramalan nilai ekspor untuk periode November 2025 hingga Maret 2026 disajikan pada Tabel 5.

TABEL V
HASIL PERAMALAN NILAI EKSPOR TAHUN 2025

Periode	Peramalan
November 2025	US\$ 217,97 juta
Desember 2025	US\$ 275,48 juta
Januari 2026	US\$ 206,13 juta
Februari 2026	US\$ 219,44 juta
Maret 2026	US\$ 180,52 juta

Berdasarkan Tabel 5, hasil peramalan nilai ekspor pada periode November 2025 hingga Maret 2026 menunjukkan

pola fluktuatif antarbulan. Nilai ekspor tertinggi diperkirakan terjadi pada Desember 2025 sebesar US\$ 275,48 juta, sedangkan nilai terendah diperkirakan terjadi pada Maret 2026 sebesar US\$ 180,52 juta. Pola ini mengindikasikan adanya variasi kinerja ekspor dalam jangka pendek yang kemungkinan dipengaruhi oleh faktor musiman, perubahan permintaan pasar, serta dinamika aktivitas perdagangan pada akhir dan awal tahun. Secara keseluruhan, pergerakan nilai ekspor selama periode peramalan tidak menunjukkan tren linear yang konsisten, melainkan dinamika naik dan turun. Kondisi ini menunjukkan bahwa kinerja ekspor Provinsi Sumatera Barat masih bersifat fluktuatif dan memerlukan perhatian dalam perencanaan serta pengambilan kebijakan ekspor jangka pendek.

IV. KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, diperoleh 14 model BPNN untuk meramalkan nilai ekspor di Provinsi Sumatera Barat. Dari semua model tersebut, diperoleh model terbaik dengan arsitektur BPNN(12,12,1). Pemilihan model ini didasarkan pada nilai MSE dan MAPE yang paling rendah, yang mengindikasikan bahwa model tersebut memiliki tingkat akurasi yang paling tinggi dibandingkan dengan model lainnya. Oleh karena itu, model BPNN(12,12,1) dinilai efektif dalam meramalkan nilai ekspor di Provinsi Sumatera Barat. Model terbaik tersebut selanjutnya digunakan untuk menghasilkan keluaran peramalan jangka pendek, yaitu nilai ekspor untuk periode November, Desember 2025 dan Januari hingga Maret 2026, berdasarkan pola historis data nilai ekspor dari Januari 2006 hingga Oktober 2025. Hasil penelitian ini diharapkan dapat menjadi acuan dalam meramalkan nilai ekspor di masa yang akan datang, serta dapat digunakan sebagai alat bantu dalam pengambilan keputusan di bidang ekonomi. Selain itu, penelitian ini juga diharapkan dapat memberikan kontribusi sebagai referensi bagi penelitian-penelitian selanjutnya yang mengangkat isu serupa.

DAFTAR PUSTAKA

- [1] L. Judijanto and A. Azis, "Impact Of International Trade On Regional Economic Growth," vol. 1, no. 7, pp. 1–10, 2024, doi: 10.62872/jagdc251.
- [2] B. P. Sumbar., "Statistik Ekspor Provinsi Sumatera Barat 2022," Badan Pusat Statistik Provinsi Sumatera Barat, Padang, Sumatera Barat, 2023. [Online]. Available: <https://sumbar.bps.go.id/id/publication/2023/10/23/c7685c3f5bb12dba1645c7c2/statistik-ekspor-provinsi-sumatera-barat-2022.html>
- [3] IMF, "World Economic Outlook: The Great Lockdown," International Monetary Fund, Washington, DC, 2020. [Online]. Available: <https://www.imf.org/en/-/media/files/publications/weo/2020/april/english/text.pdf>
- [4] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. Melbourne, Australia: OTexts, 2021.
- [5] Irwandi and D. P. Sari, "Analisis Metode Arima Pada Peramalan Nilai Ekspor Sumatera Barat," *UNPjoMath*, vol. 6, no. 4, pp. 9–15, 2021.
- [6] M. Khashei and M. Bijari, "A novel hybridization of artificial

- neural networks and ARIMA models for time series forecasting,” vol. 11, pp. 2664–2675, 2011, doi: 10.1016/j.asoc.2010.10.015.
- [7] G. Zhang, B. E. Patuwo, and M. Y. Hu, “Forecasting with artificial neural networks: The state of the art,” *Int. J. Forecast.*, vol. 14, no. 1, pp. 35–62, 1998.
- [8] A. Tarsauliya and R. Kala, “Analysis of Artificial Neural Network for Financial Time Series Forecasting,” vol. 9, no. 5, pp. 16–22, 2010.
- [9] I. A. Saputra, A. V. Vitianingsih, Y. Kristyawan, and A. L. Maukar, “Forecasting Model of Export and Import Value of Oil and Gas Using Gated Recurrent Unit Method,” vol. 13, no. 2, pp. 239–243, 2024, doi: 10.34148/teknika.v13i2.861.
- [10] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [11] P. L. McDermott and C. K. Wikle, “Bayesian recurrent neural network models for forecasting and quantifying uncertainty in spatial-temporal data,” *Entropy*, vol. 21, no. 2, p. 184, 2019.
- [12] T. Li, “Analysis of Comprehensive Artificial Neural Network Computer Media Aided Construction of Economic Forecasting Model,” *J. Electr. Comput. Eng.*, 2022.
- [13] T. Yuniarti *et al.*, “Penggunaan artificial neural network (ann) untuk memodelkan volume ekspor crude palm oil (cpo) di indonesia,” *Reg. Dev. Ind. Heal. Sci. Technol. Art Life*, pp. 247–255, 2019.
- [14] C. Zhou, C. Che, X. S. Zhang, Q. Zhang, and D. Zhou, “Harmonized system code prediction of import and export commodities based on Hybrid Convolutional Neural Network with Auxiliary Network,” *Knowledge-Based Syst.*, vol. 256, p. 109836, 2022.
- [15] W. Robiansyah and H. Okprana, “Analisis Algoritma JST untuk Prediksi Perkembangan PDRB Menurut Lapangan Usaha Atas Dasar Harga Berlaku,” vol. 6, no. 1, pp. 374–385, 2024, doi: 10.47065/josyc.v6i1.5994.
- [16] A. Hermawan, “Jaringan Saraf Tiruan Teori dan Aplikasi,” *Andi, Yogyakarta*, 2006.
- [17] Supriyanto, Sunardi, and I. Riadi, “Pengaruh nilai hidden layer dan learning rate terhadap kecepatan pelatihan jaringan syaraf tiruan backpropagation 1,” *JIKO (Jurnal Inform. dan Komputer)*, vol. 6, no. 1, pp. 27–33, 2022.
- [18] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*. OTexts, 2018.
- [19] T. Yuniarti, J. Astuti, I. Rusmar, I. Widiana, F. Ciputra, and D. Bani, “Komparasi Metode Regresi Linier , Exponential Smoothing dan ARIMA Pada Peramalan Volume Ekspor Minyak Kelapa Sawit di Indonesia,” vol. 3, no. 1, pp. 1–15, 2022.
- [20] S. Makridakis, S. C. Wheelwright, and R. J. Hyndman, *Forecasting methods and applications*. John wiley & sons, 2008.
- [21] D. C. I. Astuti, D. M. Khairina, and S. Maharani, “Peramalan nilai ekspor nonmigas kalimantan timur dengan metode double moving average (dma),” *Adopsi Teknol. dan Sist. Inf.*, vol. 2, no. 1, pp. 20–34, 2023.