

Penerapan Jaringan Saraf Tiruan dengan Metode *Backpropagation* untuk Peramalan Kurs Dolar Amerika terhadap Rupiah

Hery Sethio, Dewi Murni

Departemen Matematika, Universitas Negeri Padang

Article Info

Article history:

Received July 31, 2025

Revised Agustust 09, 2025

Accepted January 19, 2026

Keywords:

Artificial Neural Network

Multi Layer Perceptron

Backpropagation

US Dollar

Time Series Forecasting

Kata Kunci:

Jaringan Saraf Tiruan

Multi Layer Perceptron

Backpropagation

Dolar Amerika

Peramalan Deret Waktu

ABSTRACT

The highly fluctuating exchange rate of the United States Dollar against the Indonesian Rupiah creates significant economic uncertainty, necessitating accurate forecasting tools for proactive policy measures. This research aims to determine the optimal configuration of an Artificial Neural Network model, evaluate its accuracy in model development, and present the forecast results for the exchange rate. The data analysis utilizes a model trained with the backpropagation algorithm and Adam optimization, the model's performance is subsequently evaluated using Mean Absolute Percentage Error. The findings indicate that the optimal model configuration is a 12-5-1 architecture, trained for 4000 epochs with an 80:20 data split for training and testing. This model is highly accurate, demonstrating a Mean Absolute Percentage Error value of 1.8764%. The forecast projects the exchange rate to be within the range of IDR 15,614–IDR 15,850 during the period of January–June 2025.

ABSTRAK

Nilai tukar Dolar Amerika terhadap Rupiah yang sangat fluktuatif dapat menciptakan ketidakpastian ekonomi, sehingga memerlukan alat peramalan yang akurat untuk kebijakan proaktif. Penelitian ini bertujuan untuk menentukan konfigurasi model Jaringan Saraf Tiruan yang optimal serta mengukur tingkat akurasi dalam membangun model dan mengetahui hasil peramalan kurs. Analisis data menggunakan model yang dilatih dengan algoritma *backpropagation* dan optimasi *Adam*, lalu kinerja model dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan konfigurasi model yang optimal adalah model arsitektur 12-5-1 dilatih selama 4000 epoch dengan rasio data 80:20 dan tingkat akurasi model ini sangat akurat, dengan nilai MAPE sebesar 1,8764%. Hasil peramalan menunjukkan kurs berada pada rentang Rp15.614–Rp15.850 di periode Januari–Juni 2025.

This is an open access article under the [CC BY-SA](#) license.



Penulis Korespondensi:

Hery Sethio

Departemen Matematika, Universitas Negeri Padang,

Email: herysethio555@gmail.com

1. PENDAHULUAN

Nilai tukar Dolar Amerika (USD) terhadap Rupiah (IDR) menjadi indikator utama yang merefleksikan stabilitas ekonomi nasional. Dominasi Dolar Amerika dalam konteks global tercermin dari penggunaan mata uang tersebut sebagai denominasi utama pada cadangan devisa, utang luar negeri, serta transaksi perdagangan internasional [1]. Peran Dolar Amerika menjadi sangat penting bagi Indonesia karena sebagian besar transaksi perdagangan, termasuk ekspor dan impor, dilakukan dengan mata uang ini [2]. Oleh karena itu, fluktuasi kurs ini mempengaruhi perekonomian secara luas, mulai dari daya beli masyarakat hingga struktur biaya produksi industri, yang pada akhirnya berdampak pada inflasi.

Berdasarkan data dari Bank Indonesia [3], pergerakan kurs USD/IDR selama lebih dari dua dekade terakhir menunjukkan pola yang sangat fluktuatif. Kurs tengah USD/IDR bulanan pernah mencapai titik terendah pada Mei 2003 di level Rp8.279 dan menyentuh titik tertinggi pada Juni 2024 di angka Rp16.421. Kondisi ini memunculkan kekhawatiran bahwa kurs akan terus melemah di masa depan, sehingga pemerintah perlu menyiapkan langkah-langkah antisipatif. Mengingat peran krusialnya, fluktuasi kurs yang tajam dan tidak terprediksi dapat memberikan dampak signifikan terhadap stabilitas ekonomi. Oleh karena itu, diperlukan upaya peramalan yang akurat agar pemerintah dapat mengambil tindakan proaktif dalam merumuskan kebijakan ekonomi.

Pada dasarnya, nilai tukar mata uang ditentukan oleh mekanisme permintaan dan penawaran di pasar valuta asing [4]. Permintaan dipengaruhi oleh pembayaran impor dan aliran modal keluar, sedangkan penawaran didorong oleh penerimaan ekspor dan aliran modal masuk. Faktor makroekonomi seperti perbedaan laju inflasi dan suku bunga antar negara juga memberikan pengaruh signifikan [5]. Data pergerakan nilai tukar ini dicatat secara berkala dan membentuk data deret waktu (*time series*), yaitu data yang disusun berdasarkan urutan waktu [6], yang analisisnya menjadi dasar untuk kegiatan peramalan.

Peramalan (*forecasting*) adalah proses membuat prediksi berdasarkan data masa lalu dan saat ini [7]. Seiring kemajuan teknologi, metode prediktif berbasis *machine learning*, seperti Jaringan Saraf Tiruan menawarkan pendekatan yang lebih adaptif dan fleksibel. Jaringan Saraf Tiruan (JST) adalah jenis model pembelajaran mesin yang terinspirasi oleh struktur dan cara kerja otak manusia [8]. Keunggulan utama JST adalah kemampuannya dalam mengenali pola data yang bersifat non-linier, tidak membutuhkan asumsi distribusi data, serta lebih toleran terhadap inkonsistensi data [9]. Jaringan Saraf Tiruan bekerja melalui mekanisme *feedforward*, yaitu proses pengiriman sinyal informasi secara satu arah dari lapisan input (*input layer*) menuju lapisan output (*output layer*) melalui lapisan tersembunyi (*hidden layer*) [10]. Proses ini merupakan tahapan kalkulasi untuk menghasilkan nilai prediksi sebelum dilakukan evaluasi kesalahan. Namun, hasil prediksi dari proses ini umumnya masih memiliki deviasi terhadap data aktual, sehingga diperlukan algoritma pembelajaran untuk meminimalkan tingkat kesalahan tersebut. *Backpropagation neural network* adalah salah satu model jaringan saraf tiruan dengan arsitektur *multilayer* yang sering digunakan untuk mengatasi masalah ini melalui mekanisme pembaruan bobot guna mencapai hasil optimal [11]. Penelitian sebelumnya [12] menunjukkan bahwa metode *backpropagation* efektif dalam meramalkan tingkat inflasi di Kota Padang selama periode 2020–2022. Model tersebut menghasilkan tingkat kesalahan rendah, ditunjukkan oleh nilai *Mean Squared Error* (MSE) sebesar 0,010689. Tidak hanya di sektor ekonomi, metode ini juga digunakan untuk memprediksi data di bidang lain, seperti hasil pertandingan olahraga. Studi terkait [13] menunjukkan bahwa model ini mampu mencapai akurasi 77,89% dengan nilai MSE 0,769.

Berdasarkan hal tersebut, penelitian ini menerapkan model Jaringan Saraf Tiruan dengan algoritma *backpropagation* yang berfokus pada upaya menemukan konfigurasi arsitektur JST paling optimal. Hal ini dicapai melalui serangkaian eksperimen sistematis terhadap *hyperparameter* seperti jumlah neuron dan rasio data, dengan menggunakan data historis hingga akhir tahun 2024. Dengan demikian, penelitian ini tidak hanya bertujuan menyajikan model prediksi yang akurat, tetapi juga memberikan hasil peramalan untuk periode Januari hingga Juni 2025 sebagai kontribusi praktis bagi para pemangku kepentingan.

2. METODE

Penelitian ini merupakan jenis penelitian terapan. Jenis data yang digunakan dalam penelitian ini adalah berupa data bulanan kurs tengah USD/IDR diperoleh dari situs resmi Bank Indonesia.

Rentang waktu data yang digunakan adalah dari Januari 2001 hingga Desember 2024, dengan total 288 data. Pada penelitian ini, analisis data dilakukan dengan membangun model peramalan Jaringan Saraf Tiruan melalui proses *feedforward* [14] serta melatih model dengan menggunakan algoritma *backpropagation* [14] dan optimisasi *Adam* [15]. Langkah-langkah analisis data yang digunakan untuk mencapai tujuan penelitian ini adalah sebagai berikut:

- 1) Data mentah diubah ke dalam format deret waktu untuk membentuk pasangan input dan target. Selanjutnya, data dibagi menjadi data latih dan data uji dengan berbagai variasi rasio data latih (60%, 70%, 80%, dan 90%), lalu dinormalisasi menggunakan metode *min-max* [16].
- 2) Menginisialisasi nilai bobot dan bias secara acak untuk setiap lapisan. Neuron pada lapisan tersembunyi dilakukan beberapa kombinasi yaitu 1 neuron hingga 24 neuron.
- 3) Melakukan *feed forward* untuk menghitung output prediksi dari model berdasarkan data input.
- 4) Melatih model dengan proses *backpropagation* untuk menghitung gradien rata-rata dari fungsi *loss*.
- 5) Menggunakan algoritma optimisasi *Adam* untuk meminimalkan *error* dan memperbarui parameter model selama proses pelatihan.
- 6) Melakukan serangkaian percobaan dengan menguji kombinasi *hyperparameter* jumlah neuron (1–24) dan *epoch* (1000–10000).
- 7) Mengevaluasi kinerja model terbaik berdasarkan *Mean Absolute Percentage Error* (MAPE) dan melakukan denormalisasi untuk mengembalikan hasil prediksi ke skala aslinya.
- 8) Menyusun kesimpulan berdasarkan hasil analisis data.

3. HASIL DAN PEMBAHASAN

3.1. Deskripsi Data

Data yang digunakan dalam penelitian ini adalah data historis kurs tengah USD/IDR yang diperoleh dari situs resmi Bank Indonesia [3]. Data tersebut merupakan data bulanan dari Januari 2001 hingga Desember 2024, dengan total 288 data.



Gambar 1. Harga Kurs USD/IDR Periode Januari 2001–Desember 2024

Berdasarkan Gambar 1, data historis menunjukkan tren depresiasi (pelemahan) nilai tukar Rupiah selama periode pengamatan, yang ditandai dengan peningkatan nilai secara signifikan dari titik minimum di tahun 2003 hingga mencapai titik maksimum pada tahun 2024.

3.2. Analisis Data

3.2.1. Pra-pemrosesan Data

3.2.1.1. Format Deret Waktu

Pada tahapan ini, data dibentuk ke dalam format deret waktu, yaitu 12 periode sebelumnya digunakan untuk memprediksi periode selanjutnya. Sebagai contoh, dimulai dari pola pertama yang

menggunakan data bulan ke-1 hingga ke-12 sebagai input untuk target bulan ke-13. Proses ini berlanjut secara iteratif hingga pola terakhir (ke-276), di mana data bulan ke-276 sampai ke-287 digunakan sebagai input untuk memprediksi target bulan ke-288.

3.2.1.2. Pemisahan Data

Pada proses ini data dibagi menjadi data latih dan data uji dengan variasi proporsi 60%, 70%, 80%, dan 90%. Data deret waktu dinotasikan sebagai x_t , di mana t merepresentasikan urutan data ke- t . Rincian pembagian data latih dan data uji berdasarkan indeks data disajikan pada Tabel 1.

Tabel 1. Pemisahan Data

Proporsi	Data Latih	Data Uji
60%	$x_1, \dots, x_{165}$	$x_{166}, \dots, x_{276}$
70%	$x_1, \dots, x_{193}$	$x_{194}, \dots, x_{276}$
80%	$x_1, \dots, x_{220}$	$x_{221}, \dots, x_{276}$
90%	$x_1, \dots, x_{248}$	$x_{249}, \dots, x_{276}$

3.2.1.3. Normalisasi Data

Proses normalisasi data dilakukan menggunakan metode *min-max* dengan persamaan sebagai berikut,

$$x' = \frac{(x - X_{min})(h - l)}{X_{max} - X_{min}} + l \quad (1)$$

dengan:

- x' : Nilai yang telah normalisasi
- x : Nilai asli
- X_{min} : Nilai minimum dari data
- X_{max} : Nilai maksimum dari data
- h : Batas atas skala normalisasi
- l : Batas bawah skala normalisasi

Sebagai contoh, data dalam variasi data latih 60% dengan nilai minimum 8279 dan nilai maksimum 14657, sehingga normalisasi data dalam rentang $[-1,1]$ sebagai berikut:

$$x'(9450) = \frac{(9450 - 8279)(1 - (-1))}{14657 - 8279} + (-1) = -0.6328$$

3.2.2. Inisialisasi Parameter

Sebagai contoh, untuk 1 neuron (12-1-1), inisialisasi parameter sebagai berikut:

$$W_1 = [0.095, 0.8723, \dots, 0.0835]$$

$$b_1 = [0.5697], W_2 = [0.5333], b_2 = [0.5175]$$

dengan:

- W_1 : Bobot dari lapisan masukan ke lapisan tersembunyi
- b_1 : Bias pada lapisan tersembunyi
- W_2 : Bobot dari lapisan tersembunyi ke lapisan keluaran
- b_2 : Bias pada lapisan keluaran

Bobot dan bias untuk neuron 1 hingga 24 diinisialisasi secara acak pada setiap layer. Implementasi ini menggunakan bahasa pemrograman untuk menghasilkan matriks bobot, di mana setiap elemennya diambil secara acak dalam interval 0 hingga 1, lalu parameter acak yang dihasilkan disimpan untuk diproses dalam pelatihan.

3.2.3. Proses Feed Forward

Dalam proses *feed forward* jaringan saraf tiruan, sebagai contoh yaitu arsitektur 12-1-1, simbol x menyatakan vektor input yang terdiri dari 12 data masukan. Nilai input linear ke neuron tersembunyi

dinotasikan sebagai z_1 dan output aktivasi dari neuron tersebut dituliskan sebagai a_1 . Fungsi aktivasi yang digunakan dinotasikan dengan $S(z)$. Selanjutnya, nilai input linear ke lapisan keluaran dilambangkan dengan z_2 dan hasil prediksi dinotasikan dengan $g(x)$. Proses perhitungan *feed forward* dilakukan berdasarkan nilai input dan parameter awal jaringan sebagai berikut:

$$x = [-0.6328, -0.512, \dots, -0.3349]^T$$

$$b_1 = [0.5697]$$

$$b_2 = [0.5175]$$

$$W_1 = [0.095, 0.8723, \dots, 0.0835]$$

$$W_2 = [0.5333]$$

$$S(z_1) = \tanh(z_1)$$

$$S(z_2) = \tanh(z_2)$$

Proses perhitungan feed-forward dimulai dari lapisan input ($l = 0$) menuju lapisan tersembunyi ($l = 1$). Dengan nilai input $a_0 = x$ dan bobot W_1 serta bias b_1 yang telah diinisialisasi, perhitungan nilai z_1 adalah sebagai berikut:

$$z_1 = W_1 a_0 + b_1$$

$$z_1 = \sum (w_{1,i} \cdot x_i) + b_1$$

$$z_1 = -0.9836$$

Selanjutnya, nilai output dari lapisan tersembunyi (a_1) dihitung menggunakan fungsi aktivasi tangent hyperbolic (*tanh*)

$$a_1 = S(z_1) = \tanh(-0.9836) = -0.7546$$

Kemudian, proses dilanjutkan ke lapisan output ($l = 2$) menggunakan bobot W_2 dan bias b_2

$$z_2 = W_2 a_1 + b_2$$

$$z_2 = (0.5333 \times -0.7546) + (0.5175)$$

$$z_2 = 0.115$$

Hasil prediksi akhir (a_2) diperoleh dengan menerapkan fungsi aktivasi pada z_2 ,

$$a_2 = S(z_2) = \tanh(0.115) = 0.1145$$

Sehingga diperoleh $g(x) = 0.1145$

Hasil komputasi pada proses *feedforward* secara keseluruhan diterapkan pada data latih sebesar 60%, yang mencakup total 165 data. Pada tahapan ini, jaringan menghitung hasil prediksi $g(x)$ untuk setiap data *input*. Nilai prediksi tersebut kemudian dibandingkan dengan nilai aktual atau target (y) masing-masing data untuk menghitung besaran deviasi (*error*) yang dihasilkan sebelum memasuki tahap *backpropagation*.

3.2.4. Proses Backpropagation

Selama pelatihan model, algoritma *backpropagation* menyesuaikan bobot dan bias jaringan saraf tiruan untuk meminimalkan fungsi *loss* (C). Proses ini menghitung gradien dari fungsi *loss* terhadap parameter model (bobot dan bias) secara iteratif, dimulai dari lapisan output menuju lapisan input. Dalam proses *backpropagation*, notasi δ_i menyatakan gradien *loss* pada lapisan ke- i . Selanjutnya, dilakukan perhitungan gradien rata-rata terhadap nilai *loss* pada data pelatihan. Gradien yang dihasilkan ini kemudian digunakan dalam optimasi untuk memperbarui parameter model. Fungsi *loss* yang digunakan adalah *Mean Squared Error* (MSE), seperti yang didefinisikan dalam persamaan (2) berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - g_i(x))^2 \quad (2)$$

dengan,

- n : Total data
- y_i : Nilai aktual data ke- i
- $g_i(x)$: Nilai prediksi data ke- i

$$MSE = \frac{1}{165} [(-0.3599 - 0.1145)^2 + \dots + (1 - 0.7806)^2] \\ = 0.438$$

Untuk $n = 1$, MSE dapat dihitung dengan:

$$MSE = (y - g(x))^2$$

Langkah pertama dalam proses backpropagation adalah menghitung turunan parsial dari fungsi *loss* (MSE) terhadap hasil prediksi model ($g(x)$). Turunan ini merepresentasikan seberapa besar perubahan *error* terhadap perubahan prediksi, yang dirumuskan sebagai berikut.

$$\frac{\partial C}{\partial g(x)} = \frac{\partial}{\partial g(x)} (y - g(x))^2 = 2(g(x) - y)$$

Selanjutnya, diperlukan turunan dari fungsi aktivasi pada lapisan output (S_L) terhadap input terbobot (z_L).

$$S'(z_L) \frac{\partial S_L}{\partial z_L} = 1 - \tanh^2(z_2)$$

Dengan menerapkan aturan rantai, dapat dihitung nilai error term (δ) untuk setiap lapisan. Perhitungan pada Lapisan Output ($l = 2$) Nilai *error* pada lapisan output (δ_2) diperoleh dengan mengalikan gradien fungsi *loss* dengan turunan fungsi aktivasi.

$$\delta_2 = \frac{\partial C}{\partial g(x)} S'(z_L) = 2(g(x) - y) \cdot [1 - \tanh^2(z_2)]$$

Berdasarkan nilai δ_2 tersebut, gradien untuk pembaruan parameter bias (b_2) dan bobot (W_2) pada lapisan *output* dapat dihitung,

$$\frac{\partial C}{\partial b_2} = \delta_2 \\ \frac{\partial C}{\partial W_2} = \delta_2 a_1^T$$

Kesalahan dari lapisan output dipropagasikan kembali ke lapisan tersembunyi untuk mendapatkan nilai *error* lapisan pertama (δ_1). Perhitungan ini melibatkan bobot dari lapisan depannya (W_2) dan turunan fungsi aktivasi lapisan saat ini ($S'(z_1)$).

$$\delta_1 = S'(z_1) \odot W_2^T \delta_2$$

$$\delta_1 = (1 - \tanh^2(z_1)) \odot W_2^T \delta_2$$

Sehingga gradien untuk parameter pada lapisan tersembunyi adalah,

$$\frac{\partial C}{\partial b_1} = \delta_1 \\ \frac{\partial C}{\partial W_1} = \delta_1 a_0^T$$

$$\delta_0 = S'(z_0) \odot W_1^T \delta_1. \text{ Karena } z_0 = 0, \text{ sehingga } \delta_0 = 0$$

Komputasi nilai turunan parsial dilakukan terhadap keseluruhan himpunan data latih yang berjumlah 165 sampel. Berdasarkan hasil tersebut, tahap selanjutnya adalah menghitung gradien rata-rata guna menentukan arah pembaruan parameter model.

Untuk $l = 1$,

$$\frac{\partial C}{\partial W_1} = \frac{1}{165} \sum_{i=1}^{165} \frac{\partial C_i}{\partial W_1}$$

$$\frac{\partial C}{\partial b_1} = \frac{1}{165} \sum_{i=1}^{165} \frac{\partial C_i}{\partial b_1}$$

Untuk $l = 2$,

$$\frac{\partial C}{\partial W_2} = \frac{1}{165} \sum_{i=1}^{165} \frac{\partial C_i}{\partial W_2}$$

$$\frac{\partial C}{\partial b_2} = \frac{1}{165} \sum_{i=1}^{165} \frac{\partial C_i}{\partial b_2}$$

Hasil komputasi gradien rata-rata dari fungsi *loss* terhadap parameter model diperoleh sebagai berikut.

$$\begin{aligned} \frac{\partial C}{\partial W_1} &= [-0.0173, -0.0122, -0.0099, -0.0093, \\ &\quad -0.0083, -0.0074, -0.0089, -0.0107, \\ &\quad -0.0116, -0.0128, -0.0148, -0.0169] \\ \frac{\partial C}{\partial b_1} &= [0.0474] \\ \frac{\partial C}{\partial W_2} &= [-1.0747] \\ \frac{\partial C}{\partial b_2} &= [1.177] \end{aligned}$$

3.2.5. Optimasi Model dengan metode Adam

Tahap selanjutnya setelah memperoleh gradien rata-rata untuk seluruh parameter yaitu melakukan optimasi agar gradien yang digunakan selanjutnya mendekati nilai yang optimal. Seluruh *hyperparameter* yang digunakan dalam algoritma *Adam* merupakan pengaturan standar yang direkomendasikan [15]. Inisialisasi awal yaitu $m_0 = 0$, $v_0 = 0$, $t = 0$, $\alpha = 0.001$, $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 10^{-8}$, Inisialisasi nilai awal parameter model dinotasikan dengan θ_0 sedangkan rata-rata gradien dari fungsi *loss* terhadap parameter model dinotasikan dengan $\nabla f(\theta)$. Proses optimasi dilakukan secara iteratif untuk berbagai jumlah *epoch*, guna mengevaluasi pengaruh jumlah iterasi terhadap kinerja model dan proses konvergensi.

Parameter awal model dan gradien diinisialisasi,

$$\theta_0 = [0.5175, 0.5333, \dots, 0.0835]$$

$$\nabla f_1(\theta_0) = [1.177, -1.0747, \dots, -0.0169]$$

$t = 1$ (Epoch 1)

$$g_1 = \nabla f_1(\theta_0)$$

Langkah selanjutnya melibatkan perhitungan estimasi momen pertama (m_1) yang merepresentasikan rata-rata gradien. Nilai m_1 ditentukan menggunakan parameter $\beta_1 = 0.9$ dengan cara mengakumulasi gradien saat ini terhadap momen sebelumnya.

$$m_1 = \beta_1 \cdot m_0 + (1 - \beta_1) \cdot g_1 = [0.1177, -0.1074, \dots, -0.0016]$$

Secara simultan, Perhitungan estimasi momen kedua (v_1) melibatkan pengkuadratan (g_1^2) dengan menggunakan parameter $\beta_2 = 0.999$.

$$v_1 = \beta_2 \cdot v_0 + (1 - \beta_2) \cdot g_1^2 = [0.0013, 0.0011, \dots, 2.88E - 07]$$

Mengingat inisialisasi awal momen m_0 dan v_0 bernilai nol, hasil estimasi cenderung bias mendekati nol pada awal pelatihan. Oleh karena itu, mekanisme koreksi bias diterapkan pada momen pertama (m_1) dan momen kedua (v_1) untuk menghasilkan estimasi yang lebih akurat.

$$\widehat{m}_1 = \frac{m_1}{1 - \beta_1^1} = \frac{m_1}{1 - 0.9} = [1.177, -1.0747, \dots, -0.0169]$$

$$\widehat{v}_1 = \frac{v_1}{1 - \beta_2^1} = \frac{v_1}{1 - 0.999} = [1.3853, 1.155, \dots, 0.0002]$$


Tahap akhir dari iterasi ini adalah pembaruan parameter model (θ_1). Parameter baru ditentukan dengan mengurangi parameter lama menggunakan *learning rate* α dan konstanta ϵ .

$$\theta_1 = \theta_0 - \alpha \cdot \frac{\widehat{m}_1}{\sqrt{\widehat{v}_1} + \epsilon} = [0.5165, 0.5343, \dots, 0.0845]$$

Penyelesaian perhitungan nilai θ_1 menandai berakhirnya satu siklus epoch. Algoritma selanjutnya akan mengulangi proses iterasi tersebut untuk epoch berikutnya hingga mencapai kriteria penghentian atau jumlah maksimum *epoch* yang telah ditetapkan.

3.2.6. Percobaan Variasi Kombinasi


Pelatihan model menggunakan algoritma optimasi *Adam* dilakukan hingga mencapai batas *epoch* yang telah ditetapkan, yaitu 1000, 2000, 3000, ..., sampai 10000, dengan variasi jumlah neuron pada lapisan tersembunyi antara 1–24. Setelah data dilatih, dilakukan pengujian terhadap data uji, hasil pengujian disajikan dalam bentuk grafik berikut.



Gambar 2. Grafik Hasil Pengujian Model dengan Variasi Jumlah Neuron (1–24) dan Epoch (1000–10000)

3.2.7. Mengevaluasi Kinerja

Proses pencarian model terbaik dilakukan dengan menguji beberapa skenario, yaitu dengan memvariasikan jumlah neuron pada lapisan tersembunyi (1–24) dan rasio pembagian data. Hasil pengujian tersebut pada Gambar 2, menunjukkan bahwa rasio pembagian data sebesar 80% untuk data latih dan 20% untuk data uji memberikan kinerja paling optimal. Rasio tersebut ditandai dengan warna hijau pada grafik, yang menunjukkan performa prediksi terbaik dibandingkan dengan rasio pembagian data lainnya. Dengan menggunakan rasio terbaik ini, diperoleh konfigurasi model dengan arsitektur 12-5-1 (lima neuron pada lapisan tersembunyi) sebagai model yang optimal, dengan nilai MAPE sebesar 1,8764%. Adapun hasil pengujian model terhadap data uji yang menunjukkan kesesuaian antara nilai aktual dan hasil prediksi dapat dilihat pada Gambar 3



Gambar 3. Hasil Pengujian Model 12-5-1

3.2.8. Hasil Peramalan

Berdasarkan hasil evaluasi, model dengan arsitektur 12 neuron input, 5 neuron tersembunyi, dan 1 neuron output menunjukkan performa terbaik pada data uji dengan nilai MAPE sebesar 1.8764%. Hasil peramalan nilai tukar USD/IDR untuk periode berikutnya ditampilkan pada tabel 2.

Tabel 2. Hasil Peramalan Kurs USD/IDR

No	Periode	Hasil Peramalan
1	Januari 2025	15637.37
2	Februari 2025	15614.39
3	Maret 2025	15661.54
4	April 2025	15731.33
5	Mei 2025	15850.52
6	Juni 2025	15632.17

4. KESIMPULAN

Berdasarkan hasil penelitian, konfigurasi model Jaringan Saraf Tiruan yang optimal adalah arsitektur 12-5-1 yang dilatih selama 4000 epoch dengan rasio pembagian data 80:20. Model ini terbukti memiliki kinerja yang sangat baik, ditunjukkan dengan tingkat kesalahan prediksi yang sangat kecil, yaitu sebesar 1,8764% (berdasarkan nilai MAPE). Hal ini mengindikasikan bahwa hasil prediksi model mendekati data aktual. Adapun hasil peramalan menunjukkan nilai tukar Dolar Amerika terhadap Rupiah diproyeksikan berada pada rentang Rp15.614–Rp15.850 untuk periode Januari–Juni 2025.

REFERENSI

- [1] S. Boocker and W. David, "The changing role of the US dollar." Accessed: Mar. 23, 2025. [Online]. Available: <https://www.brookings.edu/articles/the-changing-role-of-the-us-dollar/>
- [2] A. Ardian *et al.*, "Analisis Pengaruh Depresiasi Rupiah Terhadap Dolar Amerika Serikat Pada Bidang Ekspor Dan Impor," *Inisiatif: Jurnal Ekonomi, Akuntansi dan Manajemen*, vol. 3, no. 3, pp. 90–101, 2024, [Online]. Available: <https://doi.org/10.30640/inisiatif.v3i3.2580>
- [3] Bank Indonesia, "Kurs Transaksi BI." Accessed: Mar. 23, 2025. [Online]. Available: <https://www.bi.go.id/id/statistik/informasi-kurs/transaksi-bi/>
- [4] A. Risman, *Kurs Mata Uang dan Nilai Perusahaan*, no. March. 2021.
- [5] I. Simorangkir, "Sistem dan Kebijakan," *Sistem dan Kebijakan Nilai Tukar*, vol. 12, no. 12, p. 4, 2004.
- [6] Faradiba, "Analisis Data Berkala (Time Series)," 2020.
- [7] G. Zhang, B. Eddy 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, doi: 10.1016/S0169-2070(97)00044-7.
- [8] L. Harris, "Neural Networks for Predicting Stock Market Trends," no. December, 2024.
- [9] Y. A. Winata, "Model Peramalan Nilai Tukar Mata Uang Menggunakan Metode Hybrid GLARANN," vol. 03, no. 02, pp. 1–20, 2020.
- [10] S. Dutt, S. Chandramouli, and A. K. Das, "Machine Learning," 2022.
- [11] N. Ketut and T. Tastrawati, "Peramalan Menggunakan Metode Backpropagation," vol. 7, no. 3, pp. 264–270, 2018.
- [12] Atikah and D. Ahmad, "Forecasting Inflation Rate in Padang City Using Backpropagation Method," *Rangkiang Mathematics Journal*, vol. 1, no. 1, pp. 25–33, 2022, doi: 10.24036/rmj.v1i1.4.

- [13] D. Murni, P. S. Matematika, and U. N. Padang, "PREDIKSI HASIL PERTANDINGAN SEPAK BOLA LIGA PREMIER INGGRIS DENGAN ARTIFICIAL NEURAL NETWORK," vol. 4, no. 3, pp. 1523–1531, 2023.
- [14] D. P. Kroese, Z. I. Botev, T. Taimre, and R. Vaisman, "Data Science and Machine Learning," vol. 1, 2022.
- [15] D. P. Kingma and J. L. Ba, "Adam: A method for stochastic optimization," *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, pp. 1–15, 2015.
- [16] Y.-S. Kim, M. K. Kim, N. Fu, J. Liu, J. Wang, and J. Srebric, "Investigating the Impact of Data Normalization Methods on Predicting Electricity Consumption in a Building Using different Artificial Neural Network Models.," *Sustain Cities Soc*, vol. 118, no. October 2023, p. 105570, 2024, doi: 10.1016/j.scs.2024.105570.