

Peramalan Kurs Rupiah Terhadap Dolar Amerika Menggunakan Jaringan Saraf Tiruan

Rifani Rizki Amelia¹, Fadhilah Fitri²

¹ Prodi Statistika, Fakultas Matematika Ilmu Pengetahuan dan Alam Universitas Negeri Padang (UNP)

² Dosen Statistika, Fakultas Matematika Ilmu Pengetahuan dan Alam Universitas Negeri Padang (UNP)

Article Info

Article history:

Received January 30, 2022

Revised August 01, 2022

Accepted September 15, 2022

Keywords:

Forecasting
Rupiah Exchange Rate
Backpropagation Artificial
Neural Network

Kata Kunci:

Peramalan
Kurs Rupiah
Jaringan Saraf Tiruan
Backpropagation

ABSTRACT

The Indonesian rupiah (IDR) exchange rate is used to gauge Indonesia's economic stability. Maintaining the IDR exchange rate's stability is critical since it has a direct impact on Indonesia's national monetary situation, particularly during the Covid-19 pandemic. Forecasting is one way to assess government policy in terms of lowering the exchange rate. The goal of this study is to use the backpropagation artificial neural network to model and predict the IDR exchange rate. This study uses daily data on the US Dollar (USD) to Indonesian Rupiah (IDR) exchange rate from March 2020 to December 2021. The best BPNN model is BP (2,5,1), which has two neurons in the input layer, five neurons in the hidden layer, and one neuron in the output layer. The prediction accuracy of this model is very good, with an RMSE value is 33,66 and a MAPE value is 0,1796%.

ABSTRAK

Kurs rupiah digunakan untuk mengukur stabilitas ekonomi Indonesia. Menjaga stabilitas nilai tukar rupiah sangat penting karena berdampak langsung pada situasi moneter nasional Indonesia, terutama di masa pandemic Covid-19. Peramalan dapat dijadikan salah satu usaha untuk menilai kebijakan pemerintah dalam hal menurunkan nilai tukar. Tujuan dari penelitian ini adalah untuk memodelkan dan memprediksi kurs rupiah menggunakan jaringan saraf tiruan propagasi balik. Data yang digunakan adalah data harian kurs rupiah terhadap dolar AS dari Maret 2020 hingga Desember 2021. Model jaringan saraf tiruan terbaik adalah BP (2,5,1) dengan dua neuron pada lapisan masukan, lima neuron pada lapisan tersembunyi, dan satu neuron pada lapisan keluaran. Keakuratan model ini sangat tinggi dengan nilai RMSE 33,66 dan nilai MAPE 0,1796%.

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



Rifani Rizki Amelia

Rifani Rizki Amelia

Prodi Statistika, Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Negeri Padang, Jl. Prof. Dr. Hamka, Air Tawar barat, Padang Utara, Padang, 25171 Padang, Sumatera Barat
Email: rifanira97@gmail.com

1. PENDAHULUAN

Nilai tukar mata uang (kurs) merupakan harga relatif dari satu mata uang ke mata uang lainnya [1]. Kurs juga dapat didefinisikan sebagai seberapa besar mata uang lokal dihargai oleh mata uang asing. Kekuatan ekonomi suatu negara diatur oleh nilai kurs mata uang [2]. Kondisi ekonomi

suatu negara dapat dikatakan relatif baik dan stabil apabila pergerakan kurs mata uang negara tersebut juga stabil. Pentingnya peran nilai kurs telah menyebabkan berbagai upaya dilakukan untuk menstabilkan posisi nilai tukar suatu negara [3]. Indonesia menerapkan sistem nilai tukar mengambang bebas (*freely floating system*) sejak tahun 1997. Sehingga kurs rupiah tidak ditentukan oleh bank sentral, melainkan oleh mekanisme pasar. Hal ini mengakibatkan nilai kurs dapat berubah setiap saat [4].

Bagi negara-negara berkembang, mata uang dolar AS memainkan peran yang sangat penting dalam perdagangan internasional karena kegiatan perdagangan menggunakan mata uang tersebut. Ketidakstabilan nilai kurs cenderung akan mengganggu aktifitas perdagangan internasional dan dapat menimbulkan kerugian ekonomi [5]. Dalam laporan Bank Indonesia, penyebaran virus Covid-19 di Indonesia memberikan tekanan cukup besar terhadap perekonomian nasional, tak terkecuali pada sektor kurs rupiah terhadap dolar AS [6]. Pada Gambar 1 disajikan pergerakan kurs rupiah terhadap dolar AS dari Maret 2020 hingga Desember 2021.



Gambar 1. Data Kurs Rupiah Terhadap Dolar Amerika Maret 2020-Desember 2021

Pada Maret 2020, kasus Covid-19 pertama di Indonesia mulai dilaporkan oleh pemerintah. Sejak saat itu, nilai kurs rupiah juga mengalami depresiasi hingga puncaknya terjadi pada awal bulan April 2020. Bahkan pada tanggal 2 April 2020, rupiah sempat jatuh ke Rp 16.825 per dolar AS. Hal ini menyebabkan nilai kurs melemah pada paruh pertama tahun 2020 yang diakibatkan oleh peningkatan aliran modal keluar di awal pandemi akibat ketidakpastian pasar keuangan global. Memasuki tahun 2021, nilai kurs rupiah terhadap dolar AS masih mengalami pergerakan naik turun yang cukup signifikan. Hal ini menggambarkan selama pandemi Covid-19, kondisi perekonomian Indonesia juga naik turun. Sehingga peramalan dilakukan untuk melihat pergerakan nilai kurs rupiah terhadap dolar AS dan dapat ditentukan tindakan yang tepat untuk menghadapi masalah tersebut.

Peramalan adalah kegiatan untuk memprediksi keadaan di masa yang akan datang dengan seakurat mungkin [7], [8]. Metode peramalan yang digunakan pada penelitian ini adalah Jaringan Saraf Tiruan (JST) atau *Artificial Neural Network* (ANN). Metode ini dipilih karena data kurs rupiah menunjukkan pola yang tidak linier, karena data tersebut berfluktuasi dengan cepat dan dapat sangat tinggi atau sangat rendah. Data ekonomi dan keuangan, seperti data saham, data inflasi, dan data kurs pada umumnya memiliki pola data nonlinear sehingga peramalan dengan menggunakan model linear kurang baik untuk diaplikasikan [9], [10], [11].

JST merupakan pemodelan taklinier yang mengikuti struktur dan fungsional dari otak manusia dan neuronnya digunakan untuk memecahkan masalah kompleks dengan lebih cepat dan tingkat kesalahan yang kecil [12]. JST dapat diaplikasikan di berbagai bidang, diantaranya untuk pengenalan pola, pemrosesan sinyal, dan peramalan [13],[14]. Model JST lebih baik dalam peramalan data *time series* berpola nonlinear [15]. Hal ini berbeda dengan model ARIMA, karena pada ARIMA diasumsikan bahwa data memiliki pola linear yang mungkin saja tidak cocok jika diterapkan pada data nonlinear [16].




Ada beberapa alasan mengapa JST menarik dan bermanfaat baik untuk pemodelan maupun peramalan. Pertama, JST tidak memerlukan asumsi seperti pada peramalan dengan metode statistika klasik untuk pemrosesan datanya. Kedua, sebuah JST dapat belajar dari pengalaman, menggeneralisasi dari contoh yang didapatnya, serta meringkas ciri-ciri penting dari *input*, bahkan pada data yang tidak berdekatan. Ketiga, JST adalah pendekatan fungsional universal. Jaringan telah terbukti mampu memprediksi setiap fungsi kontinu dengan tingkat akurasi yang diinginkan [17].

2. METODE

Data yang digunakan pada penelitian ini adalah data harian kurs rupiah terhadap dolar AS antara Maret 2020 hingga Desember 2021 sebanyak 463 observasi. Data bersumber dari Bank Indonesia. Perangkat lunak yang digunakan adalah RStudio dengan *package neuralnet*.

Metode analisis yang digunakan adalah JST *backpropagation*. *Backpropagation* merupakan metode yang menurunkan gradien untuk menurunkan jumlah kesalahan kuadrat dari keluaran jaringan [19]. Metode ini sangat efektif untuk mendeteksi pola-pola yang kompleks. Metode ini melakukan pelatihan pada jaringan agar memberikan respons yang benar berdasarkan pola masukan yang serupa namun tidak sama dengan pola yang digunakan selama pelatihan [20]. Metode JST *backpropagation* termasuk ke dalam teknik pembelajaran terawasi (*supervised learning*). Agar dapat menghasilkan jaringan yang memiliki nilai sedekat mungkin dengan data aktualnya, selisih keluaran data aktual dengan data keluaran yang diharapkan digunakan untuk mengoreksi bobot pada jaringan syaraf tiruan [21].



Gambar 2. Arsitektur Jaringan Syaraf Tiruan Propagasi Balik

Arsitektur JST *backpropagation* ditampilkan pada Gambar 2. Arsitektur JST *backpropagation* terdiri atas tiga jenis lapisan, yaitu *input layer* (menerima informasi), *hidden layer* (mengumpulkan bobot dan menjadi penghubung *input* dengan *output layer*), dan *output layer* (menghasilkan keluaran) tersebut terdiri atas n buah *input* (ditambah sebuah bias), p buah sebagai bagian dari unit *hidden layer* (ditambah dengan bias), dan m buah sebagai unit pada *output layer*. Pada arsitektur jaringan tersebut juga terdapat bobot-bobot yang menjadi penghubung antar neuron [18]. Berdasarkan arsitektur JST *backpropagation* yang terbentuk, maka didapatkan jaringan BP (n, p, m) yang nantinya akan digunakan sebagai model peramalan.

Proses pembelajaran *backpropagation* terdiri dari tiga bagian. Pertama adalah tahap *feedforward* berdasarkan *input* pelatihan. Kedua adalah tahap perhitungan dan *backpropagation* berdasarkan kesalahan terkait. Terakhir adalah tahap penyesuaian bobot yang ditetapkan agar mencapai kesalahan minimum. Ketiga tahap ini diulang hingga syarat penghentian terpenuhi. Secara umum, jumlah perulangan atau kesalahan adalah syarat penghentian yang sering dipakai. Apabila jumlah perulangan yang dilakukan sudah melebihi jumlah maksimum perulangan yang diterapkan, atau jika kesalahan yang terjadi telah lebih kecil dari batas toleransi yang dapat diterima maka iterasi berakhir [22]. Tahapan-tahapan dari proses pembelajaran dari jaringan *backpropagation* adalah sebagai berikut [23]

Langkah 0. Inisialisasi bobot secara acak (*random*).

Langkah 1. Selama kondisi berhenti *false*, lakukan langkah 2-9.

Langkah 2. Untuk setiap pasangan data latih, lakukan 3-8.

Feedforward (umpan maju)

Langkah 3. Masing-masing neuron *input* x_i ($i = 1, 2, \dots, n$) menerima sinyal *input* dan menyebarkan ke semua neuron pada lapisan di depannya. Dalam penelitian ini x_i adalah nilai kurs rupiah terhadap dolar AS yang sudah dinormalisasi

Langkah 4. Pada masing-masing neuron *hidden layer* z_j ($i = 1, 2, \dots, p$), jumlahkan dengan: $z_in_j = \sum_{i=1}^n x_i v_{ij} + v_{0j}$. Kemudian hitung fungsi aktivasi $z_j = f(z_in_j) = \frac{1}{1+e^{-z_in_j}}$ dan sebarkan ke semua neuron pada lapisan di depannya.

Langkah 5. Pada masing-masing neuron *output layer* y_k ($j = 1, 2, \dots, m$), jumlahkan dengan: $y_in_k = \sum_{j=1}^p z_j w_{jk} + w_{0k}$. Kemudian hitung fungsi aktivasi: $y_k = f(y_in_k) = \frac{1}{1+e^{-y_in_k}}$

Backpropagation of error

Langkah 6. Hitung galat (δ) pada masing-masing neuron *output layer*:

$$\delta_k = (t_k - y_k) f'(y_in_k)$$

$$f'(y_in_k) = f(y_in_k) [1 - f(y_in_k)]$$

Hitung kenaikan nilai bobot (untuk menghitung w_{jk}): $\Delta w_{jk} = \alpha \delta_k z_j$

Hitung kenaikan nilai bobot neuron bias (untuk menghitung w_{0k}): $\Delta w_{0k} = \alpha \delta_k$

Langkah 7. Hitung galat (δ) pada masing-masing neuron *hidden layer*:

$$\delta_j = \delta_in_j f'(z_in_j) = \sum_{k=1}^m \delta_k w_{jk} f'(z_in_j)$$

$$f'(z_in_j) = f(z_in_j) [1 - f(z_in_j)]$$

Hitung kenaikan nilai bobot (untuk menghitung v_{ij}): $\Delta v_{ij} = \alpha \delta_j y_i$

Hitung kenaikan nilai bobot neuron bias (untuk menghitung v_{0j}): $\Delta v_{0j} = \alpha \delta_j$

Perubahan bobot

Langkah 8. Lakukan perubahan pada semua bobot antara *hidden layer* dan *output layer* :

$$w_{jk}(new) = w_{jk}(old) + \Delta w_{jk}$$

$$w_{0k}(new) = w_{0k}(old) + \Delta w_{0k}$$

Lakukan perubahan pada semua bobot antara *input layer* dan *hidden layer* :

$$v_{ij}(new) = v_{ij}(old) + \Delta v_{ij}$$

$$v_{0j}(new) = v_{0j}(old) + \Delta v_{0j}$$

Langkah 9. Kondisi berhenti jika sesuai dengan jumlah iterasi saat pelatihan sudah maksimum atau kesalahan yang diperoleh lebih kecil dari pada kesalahan yang ditentukan.

Model JST algoritma *backpropagation* secara sistematis adalah sebagai berikut [15].

$$y_t = w_0 + \sum_{j=1}^p w_j \cdot g \left(v_{0j} + \sum_{i=1}^n v_{ij} \cdot y_{t-i} \right) + \varepsilon_t \dots (1)$$

Dimana, v_{ij} ($i = 0, 1, 2, \dots, n, j = 1, 2, \dots, p$) dan w_j ($j = 0, 1, 2, \dots, p$) adalah bobot penghubung, p adalah banyak neuron di *input layer*, dan q adalah banyak neuron di *hidden layer*.

Tahapan analisis pada penelitian ini dimulai dengan menyiapkan data yang akan digunakan yaitu data kurs Rupiah/USD periode Maret 2020 sampai dengan Desember 2021 dan melakukan eksplorasi data untuk menemukan deskripsi dan mengidentifikasi pola data. Kemudian data perlu dinormalisasi terlebih dahulu. Normalisasi data bertujuan untuk memudahkan pemrosesan dengan menskalakan data asli tanpa menghapus isi data [24]. Normalisasi biasanya digunakan untuk menghapus data yang tidak diinginkan [25]. Normalisasi yang digunakan pada penelitian ini yaitu normalisasi min-max agar data pada rentang 0 sampai 1, rumusnya adalah sebagai berikut [19].

$$x_t' = \frac{x_t - x_{min}}{x_{max} - x_{min}} \quad \dots (2)$$

keterangan:

x_t' : nilai kurs rupiah pada waktu ke- t yang telah dinormalisasi

x_t : nilai kurs rupiah pada waktu ke- t

x_{min} : nilai kurs rupiah terendah

x_{max} : nilai kurs rupiah tertinggi

Kemudian data tersebut dibagi menjadi data latih sebanyak 80% dan data uji sebanyak 20% menurut prinsip Pareto. Selanjutnya menentukan *input* dan *output layer*. *Input layer* ditentukan oleh *trial and error*, yaitu nilai kurs rupiah terhadap dolar AS beberapa hari sebelumnya yang dilihat melalui lag-lag yang signifikan pada plot PACF. Jika plot PACF terdapat garis yang memotong selang kepercayaan (garis putus-putus) berarti lag tersebut telah signifikan. Di sisi lain, saat menentukan banyaknya *hidden layer* atau neuron di setiap *hidden layer*, tidak ada aturan baku mengenai jumlah tersebut sehingga jumlah yang digunakan dapat tidak terbatas. Dalam penelitian ini, digunakan satu *hidden layer* dengan neuron sebanyak satu hingga tujuh neuron. Sementara itu, untuk *output layer* adalah nilai kurs rupiah terhadap dolar AS periode ke- t . Kemudian membangun arsitektur JST dari neuron *input* dan *output* dengan terlebih dahulu menentukan banyak *hidden layer* dan neuron pada *hidden layer*. Neuron yang ditentukan pada setiap *layer* diterapkan berulang kali pada algoritma *backpropagation* hingga diperoleh model yang diinginkan.

Setelah memperoleh jaringan-jaringan berdasarkan proses *trial and error* tersebut, maka dilakukan proses validasi dengan menggunakan data uji untuk mendapatkan model terbaik. Validasi model dapat dihitung melalui ukuran kesalahan peramalan, diantaranya adalah *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Semakin kecil nilai RMSE dan MAPE yang dihasilkan, maka semakin baik model yang digunakan untuk peramalan. Nilai RMSE dan MAPE dapat dihitung dengan rumus berikut [7].

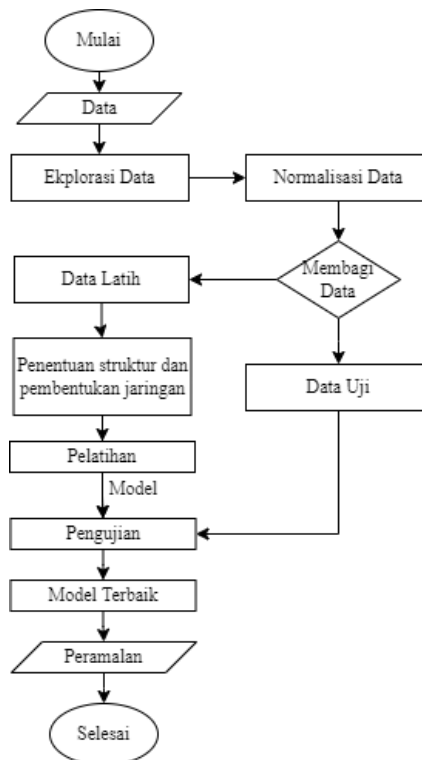
$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n [y_t - y'_t]^2} \quad \dots (3) \quad MAPE = \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad \dots (4)$$

MAPE memiliki interval nilai yang dapat digunakan sebagai pengukur kebaikan model dalam melakukan peramalan [26]. Tabel 1 menunjukkan selang nilai MAPE sebagai berikut.

Tabel 1. Selang Nilai MAPE

MAPE	Keterangan
$MAPE < 10\%$	Kemampuan prediksi sangat baik
$10\% \leq MAPE < 20\%$	Kemampuan prediksi yang baik
$20\% \leq MAPE < 50\%$	Kemampuan prediksi yang layak
$MAPE > 50\%$	Kemampuan prediksi yang buruk

Setelah mendapatkan model terbaik, maka model terbaik tersebutlah yang akan dipakai untuk meramalkan data kurs rupiah terhadap dolar AS. Berikut adalah diagram alir pada penelitian ini yang disajikan pada Gambar 3.




Gambar 3. Diagram Alir Penelitian

3. HASIL DAN PEMBAHASAN

Sebelum melakukan peramalan perlu dilakukan eksplorasi data terlebih dahulu. Eksplorasi data dilakukan untuk melihat gambaran dan mengidentifikasi data. Gambaran data tersebut dapat dilihat pada plot data. Berdasarkan Gambar 1 dapat dilihat bahwa plot data deret waktu data nilai tukar rupiah terhadap dolar AS berfluktuasi cukup tajam pada awal periode dan mengalami depresiasi hingga puncaknya pada pertengahan bulan April 2020. Bahkan rupiah sempat jatuh hingga mencapai Rp 16.825 per dolar AS pada 2 April 2020. Selanjutnya bulan Desember 2021 nilai kurs rupiah terhadap dolar AS masih berfluktuasi meskipun tidak setajam di paruh pertama tahun 2020.

Kemudian dilakukan proses normalisasi agar data yang digunakan berada pada selang 0 sampai 1. Selanjutnya adalah data tersebut dibagi menjadi dua, yaitu data latih sebanyak 80% dan data uji sebanyak 20%. Pembentukan model menggunakan data latih sedangkan validasi model dan proses peramalan menggunakan data uji. Data latih terdiri dari 370 pengamatan sedangkan data uji terdiri dari 93 pengamatan.

Selanjutnya, ada beberapa langkah yang perlu dilakukan untuk membentuk jaringan saraf tiruan yang optimal. Pertama, menentukan jumlah *input*, *hidden*, dan *output layer*. Lag-lag yang signifikan pada plot PACF digunakan sebagai penentu neuron pada *input layer* dan hanya diambil lag-lag pertama yang signifikan. Gambar 4 menyajikan plot PACF dari data kurs rupiah terhadap dolar AS. Berdasarkan plot PACF tersebut ditunjukkan bahwa plot PACF yang signifikan berada pada lag 1, 2, dan 3. Oleh karena itu, peramalan kurs rupiah terhadap dolar AS menggunakan *input* berupa lag data deret waktu ($y_{t-1}, y_{t-2}, y_{t-3}$), sementara *output* merupakan data deret waktu ke- t (y_t). Jaringan ini kemudian membentuk hubungan antara data pada periode ke- t (y_t) dengan data pada periode - periode sebelumnya ($y_{t-1}, y_{t-2}, y_{t-3}$). Sementara itu dalam menentukan banyaknya *hidden layer* ataupun neuron di tiap *hidden layer* yang digunakan dapat berjumlah tidak terbatas karena tidak ada aturan baku mengenai jumlah tersebut.



Gambar 4. Plot PACF Dari Data Kurs Rupiah Terhadap Dolar AS

Trial and error dilakukan untuk menentukan banyak *input layer* dan *hidden layer* terbaik pada jaringan saraf tiruan. Proses *trial and error* dilakukan karena sangat mempengaruhi tingkat akurasi dimana banyak neuron pada *input* dan *hidden layer* dihasilkan. Sedangkan untuk *hidden layer* digunakan satu *hidden layer* dengan neuron sebanyak satu hingga tujuh neuron. Jaringan terbaik dipilih berdasarkan nilai RMSE dan MAPE terkecil yang diperoleh pada proses *trial and error*. Jaringan dibentuk dengan mengkombinasikan antara tiga neuron pada *input layer*, tujuh neuron pada *hidden layer*, dan satu neuron pada *hidden layer*. Tabel 4 menampilkan 21 jaringan yang terbentuk dari metode *JST backpropagation*.

Tabel 2. Jaringan Saraf Tiruan Yang Terbentuk Hasil Trial and Error

Jaringan	Lag Input	RMSE	MAPE (%)
BP (1,1,1)	1	36,48	0,1856
BP (2,1,1)	1,2	35,81	0,1853
BP (3,1,1)	1,2,3	36,02	0,1869
BP (1,2,1)	1	34,29	0,1819
BP (2,2,1)	1,2	34,4	0,185
BP (3,2,1)	1,2,3	34,13	0,1826
BP (1,3,1)	1	34,10	0,1808
BP (2,3,1)	1,2	34,13	0,1823
BP (3,3,1)	1,2,3	34,23	0,1828
BP (1,4,1)	1	33,85	0,18
BP (2,4,1)	1,2	33,96	0,1806
BP (3,4,1)	1,2,3	34,28	0,1833
BP (1,5,1)	1	33,93	0,1802
BP (2,5,1)*	1,2	33,66	0,1796
BP (3,5,1)	1,2,3	33,94	0,1821
BP (1,6,1)	1	34,01	0,1804
BP (2,6,1)	1,2	33,93	0,1812
BP (3,6,1)	1,2,3	33,91	0,1814
BP (1,7,1)	1	33,87	0,18
BP (2,7,1)	1,2	33,87	0,1812
BP (3,7,1)	1,2,3	33,89	0,1813


*model jaringan saraf tiruan terbaik

Berdasarkan Tabel 2 ditunjukkan kemungkinan jaringan terbaik yang dapat digunakan pada peramalan kurs rupiah terhadap dolar AS. Jaringan yang dipilih adalah jaringan dengan nilai kriteria akurasi terendah. Kriteria akurasi yang dipakai pada penelitian ini yaitu RMSE dan MAPE. Jaringan dengan nilai RMSE dan MAPE terendah adalah jaringan terbaik dan digunakan untuk meramalkan kurs rupiah terhadap dolar AS. Tabel 3 juga menunjukkan bahwa penambahan neuron pada *input*

layer ataupun *hidden layer* tidak menjamin jaringan yang terbentuk akan menjadi semakin baik. Dari penambahan neuron tersebut tidak membuat nilai RMSE ataupun MAPE semakin mengecil.

Berdasarkan 21 jaringan yang terbentuk, diperoleh jaringan BP (2,5,1) memiliki nilai RMSE terkecil yaitu 33,66 dan nilai MAPE terkecil juga yaitu 0,1796%. Sedangkan nilai RMSE dan MAPE pada data latih dari jaringan BP (2,5,1) adalah 81,51 dan 0,3719. Hal ini menunjukkan bahwa jaringan BP (2,5,1) terpilih sebagai jaringan yang paling baik dibandingkan 20 jaringan lainnya. Sehingga jaringan BP (2,5,1) inilah yang akan digunakan pada proses validasi. Berdasarkan nilai MAPE yang dihasilkan, diperoleh hasil bahwa model BP (2,6,1) memiliki kemampuan peramalan yang sangat baik. Jaringan BP (2,5,1) tersebut dapat didefinisikan secara matematis sebagai berikut.

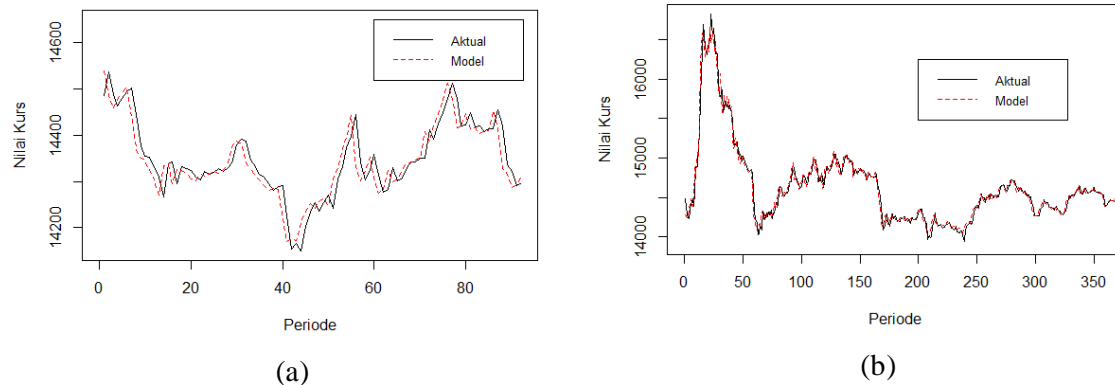
$$y_t = w_0 + \sum_{j=1}^5 w_j \cdot g \left(v_{0j} + \sum_{i=1}^2 v_{ij} \cdot y_{t-i} \right) + \varepsilon_t$$



Gambar 5. Arsitektur Jaringan BP (2,5,1)

Pada Gambar 5 ditampilkan arsitektur jaringan BP (2,5,1) yang memiliki *input layer* sebanyak dua, yaitu y_{t-1}, y_{t-2} . Lima neuron di *hidden layer* menghubungkan *input* dan *output layer*. Nilai bobot yang menghubungkan neuron pada *input* dengan *hidden layer* dan neuron pada *hidden layer* dengan *output layer* juga disajikan pada Gambar 5. Bobot-bobot tersebut dihasilkan dari pengacakan bilangan yang dihasilkan di *software* RStudio. Model terbaik BP (2,5,1) dari data latih inilah yang akan digunakan pada peramalan kurs rupiah terhadap dolar AS.

Selanjutnya adalah prediksi model JST terbaik yang didapatkan sebelumnya yaitu BP (2,5,1) dengan data uji. Hal ini dilakukan untuk melihat tingkat akurasi peramalan yang dihasilkan dari metode jaringan saraf tiruan *backpropagation*. Pada Gambar 6(a) ditampilkan perbandingan hasil prediksi dengan data uji kurs rupiah terhadap dolar AS periode 24 Agustus 2021 sampai 31 Desember 2021. Peramalan dengan metode jaringan saraf tiruan ini cenderung mengikuti pola data aktual. Selain menggunakan grafik, kebaikan hasil peramalan juga dapat dilihat menggunakan kriteria akurasi, yaitu RMSE dan MAPE. Seperti yang sudah dijelaskan sebelumnya, model BP (2,5,1) ini menghasilkan RMSE sebesar 33,66 dan MAPE sebesar 0,1796%. Sehingga dapat disimpulkan bahwa metode JST *backpropagation* sangat baik digunakan dalam kasus peramalan kurs rupiah terhadap dolar AS. Perbandingan hasil prediksi dengan data latih kurs rupiah terhadap dolar AS juga disajikan pada Gambar 6(b). Berdasarkan Gambar 6(b), terlihat bahwa hasil latih jaringan BP (2,5,1) dapat mengikuti pola data aktual meskipun data kurs rupiah terhadap dolar AS yang digunakan sangat fluktuatif.



Gambar 6. Hasil Prediksi Model Jaringan Saraf Tiruan Dengan Data Latih (a) Dan Data Uji (b)

Sebelum melakukan peramalan untuk periode selanjutnya, maka terlebih dahulu perlu dilakukan *postpreprocessing* pada data. Pada tahap ini data dinormalisasi ke nilai awalnya. Tabel 3 menyajikan hasil peramalan kurs rupiah terhadap dolar AS untuk 20 periode selanjutnya menggunakan model jaringan saraf tiruan BP (2,5,1).

Tabel 3. Hasil Peramalan Kurs Rupiah Terhadap Dolar AS Untuk 20 Periode Selanjutnya

Tanggal	Hasil Peramalan	Tanggal	Hasil Peramalan
3-Jan-22	14.308,19	17-Jan-22	14.370,5
4-Jan-22	14.336,33	18-Jan-22	14.373,51
5-Jan-22	14.340,35	19-Jan-22	14.382,56
6-Jan-22	14.349,39	20-Jan-22	14.381,55
7-Jan-22	14.341,35	21-Jan-22	14.394,62
10-Jan-22	14.381,55	24-Jan-22	14.396,63
11-Jan-22	14.436,83	25-Jan-22	14.441,85
12-Jan-22	14.467,98	26-Jan-22	14.425,77
13-Jan-22	14.431,8	27-Jan-22	14.418,74
14-Jan-22	14.394,62	28-Jan-22	14.398,64

4. Kesimpulan

Berdasarkan hasil penelitian, model JST *backpropagation* terbaik untuk data kurs rupiah terhadap dolar AS adalah BP (2,5,1). Karena jumlah lag yang signifikan pada grafik PACF digunakan sebagai penentu banyak input pada model JST, maka pemodelan JST *backpropagation* yang terbentuk menunjukkan bahwa kurs rupiah terhadap dolar AS dipengaruhi oleh nilai kurs satu dan dua hari sebelumnya.

Berdasarkan nilai RMSE dan MAPE yang diperoleh, dapat ditunjukkan bahwa metode JST *backpropagation* sangat baik dalam meramalkan kurs rupiah terhadap dolar AS. Model BP (2,5,1) menghasilkan nilai RMSE sebesar 33,66 dan nilai MAPE sebesar 0,1796%. Pola hasil ramalan menggunakan metode JST *backpropagation* juga mengikuti fluktuasi nilai aktual dari data kurs rupiah terhadap dolar AS.

Ucapan Terimakasih

Ucapan terima kasih penulis tunjukkan pada Allah Swt. Atas nikmat dan rahmatnya penulis berhasil menyelesaikan jurnal ini. Tak lupa kepada orangtua yang senantiasa memberikan do'a pada penulis serta pada dosen pembimbing yang sudah membimbing penulis sampai terselesainya jurnal ini.

REFERENSI

- [1] F. Syarifuddin, *Konsep, Dinamika dan Respon Kebijakan Nilai Tukar Di Indonesia*, no. 24. Jakarta: BI Institute, 2015.
- [2] M. Asadullah, A. Bashir, and A. R. Aleemi, "Forecasting Exchange Rates: An Empirical Application to Pakistani Rupee," *J. Asian Financ. Econ. Bus.*, vol. 8, no. 4, pp. 339–347, 2021, doi: 10.13106/jafeb.2021.vol8.no4.0339.
- [3] F. Ardiyanto and A. Ma'ruf, "Pergerakan Nilai Tukar Rupiah Terhadap Dolar Amerika Dalam Dua Periode Penerapan Sistem Nilai Tukar," *J. Ekon. dan Stud. Pembang.*, vol. 15, no. 2, pp. 127–134, 2014, [Online]. Available: <https://media.neliti.com/media/publications/78141-ID-none.pdf>.
- [4] D. T. Utari, "Forecasting The Exchange Rate (IDR) of US Dollar (USD) Using Locally Stationary Wavelet," *EKSAKTA J. Sci. Data Anal.*, vol. 18, pp. 145–154, 2018, doi: 10.20885/eksakta.vol18.iss2.art6.
- [5] H. P. B. Santosa and T. E. Pratiwi, "Analisis Perilaku Kurs Rupiah (IDR) Terhadap Dollar Amerika (USD) Pada Sistem Kurs Mengambang Bebas di Indonesia Periode 1997.3 – 2011.4," *Diponegoro J. Econ.*, vol. I, no. 1, pp. 1–13, 2012.
- [6] Bank Indonesia, "Laporan Perekonomian Indonesia 2020," 2020.
- [7] D. Montgomery, C. Jennings, and M. Kulahci, *Time Series Analysis and Forecasting Methods*. New Jersey: Wiley, 2015.
- [8] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice, 2nd edition*, 2nd Editio. Melbourne, Australia, 2018.
- [9] M. K. Okasha and A. A. Yassen, "The Application of Artificial Neural Networks in Forecasting Economic Time Series," *Int. J. Stat. Anal.*, vol. 3(2), no. February, pp. 157–177, 2013, doi: 10.1109/DeSE51703.2020.9450779.
- [10] C. Y. Rumaruson, L. J. Sinay, and M. I. Tilukay, "Indonesian rupiah exchange rate prediction using a hybrid ARIMA and neural network model," in *AIP Conference Proceedings*, 2021, vol. 2360, no. September, doi: 10.1063/5.0059512.
- [11] J. D. Cryer and K.-S. Chan, *Time Series Analysis: With Applications to R*, 2nd editio. New York: Springer, 2008.
- [12] D. A. Adeyinka and N. Muhajarine, "Time series prediction of under-five mortality rates for Nigeria: comparative analysis of artificial neural networks, Holt-Winters exponential smoothing and autoregressive integrated moving average models," *BMC Med. Res. Methodol.*, vol. 20, no. 1, pp. 1–11, 2020, doi: 10.1186/s12874-020-01159-9.
- [13] J. Keller, D. Liu, and D. Fogel, *Fundamental of Computational Intelligence Neural Networks, Fuzzy System, and Evolutionary Computation*. New Jersey: John Wiley & Sons, 2016.
- [14] Y. A. Lesnussa, F. Y. Rumlawang, and B. P. Tomasouw, "Application of backpropagation artificial neural network to predict human development index of Maluku Province Application of Backpropagation Artificial Neural Network to Predict Human Development Index of Maluku Province," in *AIP Conference Proceedings*, 2021, no. September, doi: <https://doi.org/10.1063/5.0059475>.
- [15] A. A. Adebisi, A. O. Adewumi, and C. K. Ayo, "Comparison of ARIMA and artificial neural networks models for stock price prediction," *J. Appl. Math.*, vol. 2014, pp. 1–7, 2014, doi: 10.1155/2014/614342.
- [16] S. Suleiman and M. Sani, "Application of ARIMA and Artificial Neural Networks Models for Daily Cumulative confirmed Covid-19 Prediction in Nigeria," *Equity J. Sci. Technol.*, vol. 7, no. March 2021, pp. 83–90, 2020, [Online]. Available: <http://www.equijost.com/?mno=100633>.
- [17] M. Khashei and M. Bijari, "An artificial neural network (p, d, q) model for timeseries forecasting," *Expert Syst. Appl.*, vol. 37, no. 1, pp. 479–489, 2010, doi: 10.1016/j.eswa.2009.05.044.
- [18] J. Siang, *Jaringan Syaraf Tiruan dan Pemograman Menggunakan Matlab*. Yogyakarta: Penerbit ANDI, 2005.
- [19] T. Wahyuni, "Perbandingan ARIMA dan Artificial Neural Networks Dalam Peramalan Jumlah Positif Covid-19 di DKI Jakarta," IPB University, 2021.
- [20] S. A. Nurdela, "Aplikasi Peramalan Jumlah Kelahiran dengan Metode Jaringan Saraf Tiruan," *Indones. J. Public Heal.*, vol. 12, no. 2, pp. 213–233, 2017, doi: 10.20473/ijph.v12i1.2017.213-223.
- [21] M. D. Wuryandari and I. Afrianto, "Perbandingan Metode Jaringan Syaraf Tiruan Backpropagation Dan Leaming Vector Quantization Pada Pengenalan Wajah," *Komputa*, vol. 1, no. 1, pp. 45–51, 2012.
- [22] D. Rahakbauw, "Analisis Jaringan Saraf Tiruan Backpropagation Terhadap Peramalan Nilai Tukar Mata Uang Rupiah Dan Dolar," *J. Bekerjng*, vol. 8, no. 2, pp. 27–32, 2014.
- [23] Laurene Fausett, *Fundamental of Neural Networks: Architectures, Alghorithms, and Applications*. New Jersey: Prentice Hall, 1994.
- [24] A. Zhurlina, "Prediksi Trafik Data Pada Jaringan Telekomunikasi Menggunakan Metode Jaringan Saraf Tinuan Propagasi Balik," IPB University, 2014.
- [25] S. Kumar Chandar, M. Sumathi, and S. N. Sivanandam, "Forecasting of foreign currency exchange rate using neural network," *Int. J. Eng. Technol.*, vol. 7, no. 1, pp. 99–108, 2015.
- [26] P. C. Chang, Y. W. Wang, and C. H. Liu, "The development of a weighted evolving fuzzy neural network for PCB sales forecasting," *Expert Syst. Appl.*, vol. 32, no. 1, pp. 86–96, 2007, doi: 10.1016/j.eswa.2005.11.021.