

# Prediksi Nilai Tukar MYR/IDR Menggunakan Metode RNN Dengan Optimasi PSO

R. Taufik Utomo Iswanindra Kusuma<sup>1</sup>, Mohammad Idhom<sup>2\*</sup>, Amri Muhaimin<sup>3</sup>

<sup>1,2,3</sup> Sains Data, Universitas Pembangunan Nasional “Veteran” Jawa Timur

[122083010108@student.upnjatim.ac.id](mailto:122083010108@student.upnjatim.ac.id)

[3amri.muhamin.stat@upnjatim.ac.id](mailto:3amri.muhamin.stat@upnjatim.ac.id)

\*Corresponding author email: [idhom@upnjatim.ac.id](mailto:idhom@upnjatim.ac.id)

**Abstrak**— Nilai tukar mata uang merupakan indikator fundamental yang mencerminkan kestabilan ekonomi suatu negara dan memiliki dampak signifikan terhadap perdagangan internasional, arus investasi, serta kebijakan moneter. Penelitian ini berfokus pada prediksi nilai tukar Ringgit Malaysia terhadap Rupiah Indonesia (MYR/IDR) menggunakan pendekatan hybrid yang menggabungkan metode *Recurrent Neural Network* (RNN) dengan algoritma *Particle Swarm Optimization* (PSO) sebagai mekanisme optimasi *hyperparameter*. Data yang digunakan merupakan data harian nilai tukar MYR/IDR dari periode 1 Januari 2019 hingga 31 Desember 2025 yang bersumber dari [investing.com](https://investing.com). Algoritma PSO dikonfigurasi dengan 100 partikel dan 20 iterasi untuk mencari kombinasi *hyperparameter* RNN yang optimal dengan meminimalkan nilai MSE pada data validasi sebagai fungsi objektif. Model yang dihasilkan dievaluasi menggunakan metrik MSE, MAE, MAPE, dan *R-Squared*. Hasil evaluasi menunjukkan performa yang sangat baik dengan nilai MAPE sebesar 0,2909% dan koefisien determinasi  $R^2$  sebesar 0,9964, yang berarti model mampu menjelaskan 99,63% variasi pergerakan nilai tukar aktual. Penelitian ini membuktikan bahwa integrasi RNN dan PSO menghasilkan model prediksi nilai tukar yang akurat, stabil, dan andal sebagai alat bantu pengambilan keputusan ekonomi.

**Kata Kunci**— Nilai Tukar, MYR/IDR, *Recurrent Neural Network*, *Particle Swarm Optimization*, Prediksi Deret Waktu, Optimasi *Hyperparameter*.

## I. PENDAHULUAN

Nilai tukar mata uang merupakan salah satu indikator fundamental dalam sistem perekonomian suatu negara yang mencerminkan kestabilan ekonomi dan daya saing di pasar internasional [1]. Fluktuasi nilai tukar yang tidak terduga dapat menimbulkan dampak signifikan terhadap aktivitas perdagangan lintas batas, arus investasi asing, serta kebijakan fiskal dan moneter suatu negara [2]. Oleh karena itu, kemampuan untuk memprediksi pergerakan nilai tukar secara akurat menjadi kebutuhan yang sangat penting bagi para pemangku kebijakan, pelaku pasar, maupun investor. Indonesia dan Malaysia merupakan dua negara berkembang di kawasan Asia Tenggara yang memiliki hubungan ekonomi erat, baik dalam hal perdagangan bilateral, investasi, maupun mobilitas tenaga kerja [3]. Nilai tukar Ringgit Malaysia terhadap Rupiah Indonesia (MYR/IDR) menjadi instrumen penting yang mempengaruhi neraca perdagangan kedua negara, pengiriman remitansi tenaga kerja migran Indonesia di

Malaysia, serta keputusan bisnis lintas negara. Ketidakstabilan nilai tukar MYR/IDR dapat berdampak langsung pada biaya hidup pekerja migran, daya beli masyarakat, dan volume ekspor-impor antara kedua negara.

Seiring dengan perkembangan teknologi kecerdasan buatan, pendekatan berbasis pembelajaran mesin dan pembelajaran mendalam telah banyak dimanfaatkan untuk membangun model prediksi nilai tukar yang lebih adaptif dan akurat dibandingkan metode konvensional. Model berbasis jaringan syaraf tiruan khususnya terbukti mampu menangkap pola non-linear dan ketergantungan temporal dalam data deret waktu finansial [4]. Dengan demikian, pengembangan model prediksi MYR/IDR berbasis *deep learning* menjadi relevan secara ilmiah maupun praktis untuk mendukung pengambilan keputusan ekonomi yang lebih baik.

Sejumlah penelitian terdahulu telah mengkaji efektivitas berbagai model jaringan syaraf tiruan dalam prediksi nilai tukar mata uang. Birdi dkk. (2023) membandingkan model RNN dan LSTM dalam memprediksi nilai tukar INR/USD dan menemukan bahwa RNN mencapai akurasi lebih tinggi sebesar 99,893% dibandingkan LSTM yang hanya mencapai 99,365% [5]. Sejalan dengan temuan tersebut, Sumargo dan Wasito (2024) mengevaluasi algoritma RNN, LSTM, dan GRU untuk prediksi nilai tukar USD/IDR dan CNY/IDR dengan berbagai kuantitas data, dan menyimpulkan bahwa RNN secara umum mengungguli GRU dan LSTM terutama pada data deret waktu dengan jumlah terbatas [6]. Namun, kedua penelitian tersebut masih belum mengintegrasikan algoritma optimasi *hyperparameter* sehingga potensi performa model RNN yang dihasilkan belum sepenuhnya dimaksimalkan. Di sisi lain, Pramuntadi (2017) membuktikan bahwa penerapan *Particle Swarm Optimization* (PSO) sebagai metode seleksi fitur pada *Neural Network* mampu menurunkan nilai RMSE dari 0,466 menjadi 0,373, yang mengindikasikan peningkatan akurasi prediksi yang signifikan [7]. Lebih lanjut, Saputra dkk. (2025) menunjukkan bahwa optimasi parameter *Neural Network* menggunakan PSO menghasilkan learning rate optimal sebesar 0,174 serta bobot awal yang lebih stabil, sehingga meningkatkan kecepatan konvergensi dan konsistensi proses pelatihan model secara keseluruhan [8]. Berdasarkan kajian terhadap penelitian-penelitian terdahulu, ditemukan bahwa meskipun RNN terbukti unggul dalam prediksi nilai tukar mata uang, namun belum mengadopsi mekanisme optimasi *hyperparameter* pada model RNN yang

digunakan. Celah penelitian ini menjadi penting untuk ditangani karena pemilihan *hyperparameter* yang tidak optimal dapat membatasi performa model secara signifikan. Oleh karena itu, penelitian ini mengusulkan pendekatan baru berupa penggabungan model RNN dengan algoritma PSO sebagai metode optimasi *hyperparameter*, khususnya untuk memprediksi nilai tukar MYR/IDR.

## II. TINJAUAN PUSTAKA

### A. Nilai Tukar Mata Uang

Nilai tukar mata uang merupakan rasio harga atau nilai dari satu mata uang yang dinyatakan dalam satuan mata uang negara lain. Nilai tukar berfungsi sebagai instrumen krusial dalam memfasilitasi perdagangan internasional dan aliran modal antarnegara, di mana fluktuasinya mencerminkan dinamika permintaan serta penawaran di pasar valuta asing [9]. Pergerakan nilai tukar ini dipengaruhi oleh berbagai variabel makroekonomi, termasuk tingkat inflasi, suku bunga, stabilitas politik, dan kinerja neraca pembayaran suatu negara. Dalam konteks ekonomi global, stabilitas nilai tukar menjadi indikator penting bagi kesehatan ekonomi nasional serta menjadi dasar pertimbangan dalam pengambilan keputusan investasi dan kebijakan moneter bagi otoritas terkait.

### B. Prediksi Deret Waktu

Prediksi deret waktu atau *time series forecasting* merupakan suatu teknik pemodelan statistik dan komputasi yang bertujuan untuk memprediksi nilai masa depan berdasarkan pengamatan data yang disusun secara kronologis menurut urutan waktu [10]. Prediksi *time series* berpijak pada asumsi bahwa terdapat pola, tren, maupun siklus tertentu dalam data historis yang dapat diekstraksi untuk memberikan gambaran mengenai perilaku variabel di masa yang akan datang. Dalam domain keuangan, pendekatan ini menjadi instrumen krusial karena sifat data pasar yang dinamis, sehingga diperlukan model yang mampu menangkap ketergantungan temporal (*temporal dependency*) guna meminimalisir risiko ketidakpastian dalam pengambilan keputusan strategis.


### C. Optimasi Hyperparameter

Optimasi *hyperparameter* merupakan suatu proses krusial dalam pembangunan model pembelajaran mesin yang bertujuan untuk menemukan kombinasi parameter internal yang optimal guna meningkatkan performa dan generalisasi model [11], [23]. Berbeda dengan parameter model yang dipelajari secara otomatis selama proses pelatihan, *hyperparameter* adalah variabel yang ditentukan secara eksternal sebelum proses pembelajaran dimulai, seperti *learning rate*, jumlah *hidden layers*, atau ukuran *batch*. Penentuan nilai *hyperparameter* yang tepat sangat menentukan kemampuan model dalam menangkap pola data yang kompleks serta menghindari fenomena *overfitting* atau *underfitting* [11].

### D. Recurrent Neural Network

*Recurrent Neural Network* (RNN) merupakan salah satu arsitektur *deep learning* yang dirancang secara spesifik untuk memproses data berurutan (*sequential data*) atau deret waktu (*time series*) [5], [19]. Karakteristik utama yang membedakan

RNN dari *feedforward neural network* konvensional adalah keberadaan koneksi siklik yang memungkinkan informasi dari langkah waktu sebelumnya dipertahankan melalui mekanisme memori internal [12]. Kemampuan ini memungkinkan model untuk menangkap ketergantungan temporal dalam data, di mana prediksi pada titik waktu tertentu dipengaruhi tidak hanya oleh input saat ini, tetapi juga oleh akumulasi konteks informasi dari langkah-langkah waktu sebelumnya.



Gbr. 1 Arsitektur RNN

Dalam setiap langkah waktu, unit tersembunyi menerima dua jenis masukan: vektor input saat ini dan *hidden state* dari langkah sebelumnya. Melalui fungsi aktivasi non-linear, jaringan menghasilkan *hidden state* baru yang akan diteruskan ke langkah berikutnya. Mekanisme ini sering kali direpresentasikan melalui proses *unfolding*, di mana struktur RNN divisualisasikan sebagai serangkaian unit identik yang saling terhubung dalam satu rantai urutan waktu. Struktur rekurensi ini memberikan fleksibilitas bagi model untuk memetakan hubungan non-linear yang kompleks antar variabel dalam dimensi waktu secara kontinu.

### E. Particle Swarm Optimization

*Particle Swarm Optimization* (PSO) merupakan algoritma optimasi berbasis populasi yang termasuk dalam kategori kecerdasan kelompok (*swarm intelligence*). Algoritma ini pertama kali diperkenalkan oleh Kennedy dan Eberhart pada tahun 1995, dengan inspirasi yang berasal dari perilaku sosial kawanan burung (*flocking*) atau kumpulan ikan (*schooling*) saat mencari sumber makanan [14]. Dalam konteks komputasi, PSO digunakan sebagai metode heuristik untuk menyelesaikan masalah optimasi non-linear yang kompleks dengan mencari solusi global terbaik dalam ruang pencarian multidimensi. Keunggulan utama PSO terletak pada strukturnya yang sederhana, efisiensi komputasi yang tinggi, serta kemampuannya untuk menghindari jebakan optimum lokal (*local optima*) dibandingkan dengan algoritma optimasi konvensional berbasis gradien [13].

Mekanisme kerja PSO berpusat pada pergerakan sekumpulan partikel di dalam ruang pencarian, di mana setiap partikel merepresentasikan kandidat solusi bagi permasalahan yang sedang dioptimasi. Setiap partikel memiliki dua komponen utama, yaitu posisi dan kecepatan (*velocity*,  $v$ ), yang diperbarui secara iteratif berdasarkan pengalaman individual dan kolektif. Posisi partikel disesuaikan melalui perbandingan antara pencapaian terbaik individu yang pernah diraih (*personal best* atau  $pbest$ ) dan pencapaian terbaik yang ditemukan oleh seluruh anggota kelompok (*global best* atau  $gbest$ ). Secara matematis, pembaruan kecepatan partikel  $i$  pada dimensi  $d$  dan iterasi  $t+1$  dirumuskan pada (1).

$$v_{i,d}^{t+1} = wv_{i,d}^t + c_1r_1(pbest_{i,d} - x_{i,d}^t) + c_2r_2(gbest_d - x_{i,d}^t) \quad (1)$$

Setelah kecepatan diperbarui, posisi partikel ditentukan melalui (2).

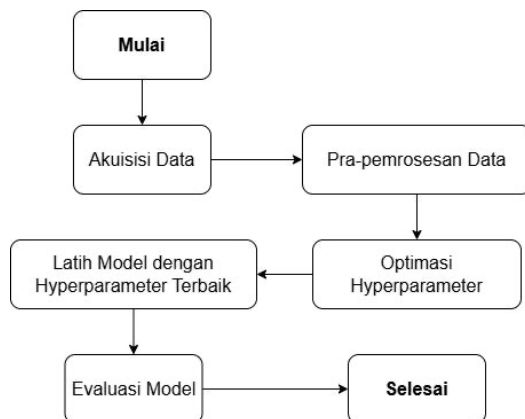
$$x_{i,d}^{t+1} = x_{i,d}^t + v_{i,d}^{t+1} \quad (2)$$

Melalui interaksi dinamis antara parameter inersia ( $w$ ), koefisien kognitif ( $c1$ ), dan koefisien sosial ( $c2$ ), seluruh kawanan partikel akan berkonvergensi menuju solusi optimal yang merepresentasikan bobot dan bias terbaik bagi jaringan saraf.

#### F. Metrik Evaluasi

Evaluasi performa model merupakan tahapan penting untuk mengukur tingkat akurasi dan keandalan hasil prediksi nilai tukar MYR/IDR yang dihasilkan oleh model. Dalam penelitian ini, efektivitas model diuji menggunakan tiga metrik evaluasi, yaitu *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan *R-Squared* ( $R^2$ ). MSE berfungsi untuk mengukur rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi, di mana metrik ini memberikan penekanan yang lebih tinggi pada kesalahan prediksi yang besar sehingga sangat efektif dalam mendeteksi adanya variansi yang signifikan [15], [20]. Sebagai pembandingan yang lebih intuitif, MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan prediksi, yang memberikan gambaran mengenai besaran kesalahan rata-rata dalam satuan yang sama dengan data asli tanpa memberikan bobot berlebih pada outlier [16], [21]. Sementara itu, MAPE digunakan untuk memberikan representasi kesalahan dalam bentuk persentase rata-rata terhadap data aktual, yang memudahkan interpretasi tingkat penyimpangan model secara relatif tanpa terpengaruh oleh skala absolut data [17], [22]. Sebagai pelengkap, *R-Squared* atau koefisien determinasi digunakan untuk mengukur sejauh mana model mampu menjelaskan variabilitas dari data target, yang memberikan gambaran mengenai tingkat kecocokan atau *goodness of fit* antara hasil proyeksi model dengan pola pergerakan nilai tukar yang sebenarnya [18].

### III. METODE PENELITIAN



Gbr. 2. Flowchart Metode Penelitian

#### A. Akuisisi Data

Data penelitian ini merupakan data sekunder nilai tukar MYR/IDR yang bersumber dari *investing.com* untuk periode 1 Januari 2019 hingga 31 Desember 2025. Data yang dikumpulkan memiliki frekuensi harian dengan atribut lengkap

meliputi harga pembukaan, harga tertinggi, harga terendah, harga penutupan. Seluruh data tersebut disusun secara kronologis untuk memastikan integritas informasi dalam analisis deret waktu.

TABEL I  
DATA NILAI TUKAR MYR/IDR

Tanggal	Penutupan	Pembukaan	Tertinggi	Terendah
01/01/2019	3.476,42	3.476,42	3.476,42	3.476,42
02/01/2019	3.489,97	3.480,16	3.500,97	3.475,53
03/01/2019	3.474,43	3.488,24	3.498,14	3.477,73
...	...	...	...	...
30/12/2025	4.141,34	4.137,30	4.149,57	4.133,36
31/12/2025	4.109,17	4.138,28	4.138,79	4.105,13

#### B. Pra-pemrosesan Data

1) *Pembersihan Data*: Tahap pembersihan data dilakukan melalui eliminasi variabel *open*, *high*, *low*, *volume*, dan *change* guna menyederhanakan struktur *dataset*. Selanjutnya, dilakukan standarisasi penamaan kolom serta penyesuaian indeks temporal untuk memastikan konsistensi format deret waktu yang siap digunakan dalam pemodelan.

2) *Ubah Tipe Data*: Proses pra-pemrosesan dilanjutkan dengan melakukan konversi tipe data pada variabel *Close* dari format teks menjadi numerik (*float*). Transformasi ini bertujuan untuk memastikan bahwa seluruh entri data nilai tukar dapat diolah secara matematis dan memenuhi syarat teknis.

3) *Membuat Variabel Target*: Pembentukan variabel target dilakukan melalui teknik pergeseran (*shifting*) pada variabel *Close* sebanyak satu periode ke depan. Transformasi ini bertujuan untuk memposisikan nilai pada waktu  $t+1$  sebagai label dependen terhadap data historis pada waktu  $t$ , sehingga struktur data memenuhi syarat untuk analisis prediktif dalam format *time series*.

4) *Menghapus Nilai Kosong*: Tahapan pembersihan data diakhiri dengan penanganan nilai kosong (*missing values*) melalui metode penghapusan baris secara menyeluruh. Prosedur ini dilakukan untuk menjaga integritas dan konsistensi *dataset*, guna menghindari diskontinuitas dalam analisis deret waktu serta memastikan bahwa setiap entri data yang digunakan memiliki informasi yang lengkap untuk tahap komputasi selanjutnya.

#### C. Optimasi Hyperparameter

Optimasi model dalam penelitian ini dilakukan melalui pencarian *hyperparameter* terbaik menggunakan algoritma PSO. Proses optimasi diarahkan untuk meminimalkan nilai MSE pada data validasi sebagai fungsi objektif. Pada setiap iterasi PSO, *dataset* dibagi dengan proporsi 70% untuk data latihan dan 30% untuk data validasi guna mengevaluasi performa setiap partikel. Eksperimen ini mengonfigurasi *swarm* yang terdiri dari 100 partikel dengan batas iterasi maksimum sebanyak 20 kali dan *seed* 42. Untuk mengatur dinamika pergerakan partikel, parameter koefisien inersia ditetapkan sebesar 0,7, sementara koefisien kognitif dan sosial masing-masing diatur pada nilai 2,0. Ruang pencarian (*search space*) yang digunakan dalam optimasi ini mencakup berbagai

parameter arsitektur dan pelatihan, mulai dari panjang sekuens, jumlah unit tersembunyi, hingga tingkat pembelajaran.

TABEL II  
RUANG PENCARIAN HYPERPARAMETER RNN DENGAN PSO

Hyperparameter	Ruang Pencarian	Step
Sequence Length	[1, 30]	1
Hidden Units	[300, 600]	10
Dropout Rate	[0.1, 0.5]	Kontinu
Batch Size	[20, 100]	20
Epochs	[200, 400]	5
Learning Rate	[0.0001, 0.01]	Kontinu
Early Stop	[5, 50]	5
Number of Layers	[1, 3]	1

Penentuan batas ruang pencarian pada Tabel II didasarkan pada tinjauan empiris dari sejumlah penelitian terdahulu yang menggunakan arsitektur RNN pada data *time-series* finansial. Rentang *sequence length* 1 sampai 30 mengikuti praktik umum pada prediksi deret waktu keuangan berfrekuensi harian, di mana dependensi temporal yang relevan umumnya berada dalam rentang satu hingga beberapa minggu perdagangan [24]. Nilai *hidden units* 300 sampai 600 dipilih berdasarkan rekomendasi untuk dataset berukuran sedang guna menjaga kapasitas representasi model tanpa menimbulkan *overfitting* berlebih [25]. *Dropout rate* pada interval [0,1; 0,5] merupakan rentang yang paling banyak digunakan pada model RNN untuk data finansial guna mencegah ko-adaptasi antar neuron [25]. *Batch size* 20 sampai 100 mencerminkan *trade-off* antara stabilitas gradien dan efisiensi komputasi yang dilaporkan pada studi serupa [26]. Rentang *epochs* 200 sampai 400 ditentukan dengan mempertimbangkan konvergensi model pada data deret waktu finansial yang dikombinasikan dengan mekanisme *early stopping* dengan ambang batas 5 sampai 50 *epochs* untuk mencegah pelatihan yang berlebihan [27]. *Learning rate* pada interval kontinu [0,0001; 0,01] mencakup rentang yang secara konsisten dilaporkan optimal untuk *optimizer* berbasis Adam pada tugas prediksi kurs valuta asing [28]. Terakhir, jumlah layer dibatasi pada 1 sampai 3 mengingat kedalaman arsitektur yang lebih dari tiga lapisan jarang memberikan peningkatan performa signifikan pada data sekuensial finansial berskala sedang [24].

#### D. Melatih Model

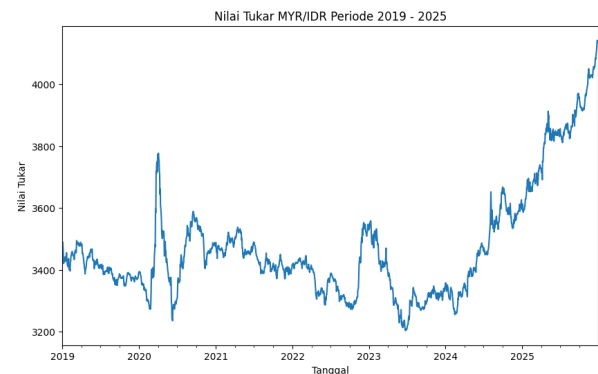
Setelah parameter optimal ditemukan melalui algoritma PSO, tahap pelatihan model final dilakukan menggunakan arsitektur RNN dengan mengaplikasikan kombinasi *hyperparameter* terbaik tersebut. Proses ini bertujuan untuk melatih model secara komprehensif pada *dataset* agar mampu menangkap pola ketergantungan temporal yang kompleks dan menghasilkan prediksi nilai tukar MYR/IDR yang akurat.

#### E. Evaluasi Model

Tahap evaluasi dilakukan untuk mengukur performa model menggunakan metrik MSE, MAE, MAPE, dan  $R^2$ . Penggunaan ketiga instrumen ini bertujuan untuk menilai akurasi, besaran kesalahan persentase, serta sejauh mana model mampu menjelaskan variansi pada data nilai tukar MYR/IDR secara komprehensif.

## IV. HASIL PENELITIAN

### A. Visualisasi Data




Gbr. 3 Grafik Nilai Tukar MYR/IDR Periode 2019 hingga 2025

Visualisasi data historis nilai tukar MYR/IDR untuk periode 2019 hingga 2025 menunjukkan karakteristik *time series* yang sangat fluktuatif dengan kecenderungan tren naik (*uptrend*) yang signifikan pada akhir periode pengamatan. Berdasarkan data tersebut, nilai tukar berada pada rentang minimum sebesar 3.203 IDR yang tercatat pada pertengahan tahun 2023, hingga mencapai titik maksimum sebesar 4.148 IDR menjelang akhir tahun 2025. Terlihat adanya volatilitas ekstrem pada awal tahun 2020 yang merefleksikan ketidakpastian pasar global, diikuti oleh fase konsolidasi hingga tahun 2022. Namun, memasuki akhir tahun 2024 hingga 2025, terjadi lonjakan nilai tukar yang konsisten melampaui level 4.000 IDR.

### B. Hasil Optimasi Hyperparameter

Optimasi *hyperparameter* pada penelitian ini dilakukan menggunakan algoritma PSO dengan konfigurasi 100 partikel, batas 20 iterasi, koefisien inersia 0,7, serta koefisien kognitif dan sosial masing-masing sebesar 2,0. Hasil eksperimen menunjukkan bahwa iterasi ke-16 merupakan titik krusial di mana algoritma berhasil mencapai nilai MSE terendah di antara seluruh iterasi yang dilakukan. Pencapaian konvergensi pada iterasi ke-16 ini mengindikasikan bahwa pergerakan partikel telah berhasil mengeksplorasi dan mengeksploitasi ruang pencarian secara efektif untuk menemukan titik minimum global sebelum mencapai batas maksimal iterasi.



Gbr. 4 Plot Historis Optimasi RNN dengan PSO

Berdasarkan proses optimasi tersebut, ditemukan konfigurasi *hyperparameter* RNN yang paling optimal sebagaimana dirinci pada Tabel III. Hasil pencarian menunjukkan bahwa penggunaan struktur jaringan dengan satu *layer* dan jumlah *units* yang besar mampu menangkap pola temporal data secara mendalam. Selain itu, pemilihan *learning rate* dan *batch size* yang tepat melalui evolusi partikel hingga iterasi ke-16 tersebut


memungkinkan model untuk mencapai stabilitas yang baik selama 220 *epochs*.

TABEL III  
HASIL OPTIMASI HYPERPARAMETER RNN DENGAN PSO

Hyperparameter	Nilai
Sequence Length	1
Hidden Units	450
Dropout Rate	0,2670
Batch Size	40
Epochs	220
Learning Rate	0,003442
Early Stop	50
Number of Layers	1

Penggunaan nilai *dropout* yang spesifik pada tabel tersebut juga terbukti efektif dalam menjaga keseimbangan antara kemampuan generalisasi model dan pencegahan *overfitting* pada data kurs yang fluktuatif. Implementasi hyperparameter hasil optimasi PSO ini menghasilkan kinerja model yang sangat akurat dengan nilai MSE terbaik sebesar 178,111788.

### C. Hasil Latih Model



Gbr. 5 Kurva Loss MSE Model

Berdasarkan hasil pengujian, proses pelatihan model RNN dengan optimasi PSO menunjukkan karakteristik konvergensi yang sangat baik. Sebagaimana divisualisasikan pada Gbr. 5, kurva MSE baik pada data latih maupun data validasi mengalami penurunan yang signifikan dan tajam pada 25 *epoch* pertama. Hal ini mengindikasikan bahwa kombinasi *hyperparameter* yang dihasilkan oleh algoritma PSO mampu mengarahkan model untuk mempelajari pola fluktuasi nilai tukar MYR/IDR secara efisien sejak awal iterasi. Stabilitas kurva setelah fase penurunan tersebut menunjukkan bahwa model tidak mengalami osilasi yang ekstrem, yang menandakan proses pembelajaran berjalan secara konsisten. Meskipun batas maksimal *epoch* yang ditetapkan adalah 220, proses pelatihan berhenti secara otomatis pada *epoch* ke-176 melalui mekanisme *early stopping* dengan parameter *patience* sebesar 50. Hasil pemulihan bobot model menunjukkan bahwa performa optimal dicapai pada *epoch* ke-126, yang merupakan titik dengan nilai *loss* validasi terendah sebelum terjadi stagnasi.

### D. Evaluasi Model

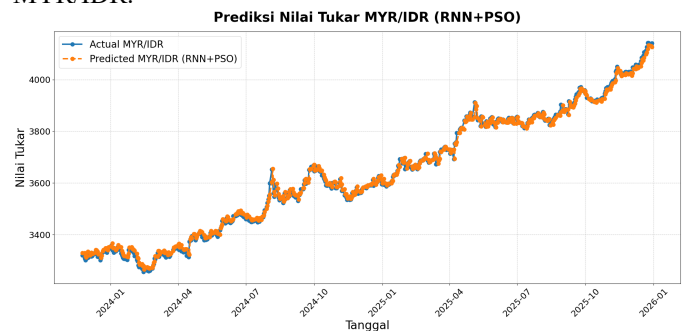
Hasil evaluasi model RNN yang dioptimasi menggunakan PSO menunjukkan tingkat akurasi yang sangat tinggi pada data

validasi sebesar 30%. MAPE yang sangat rendah, yaitu sebesar 0,2909%, mengindikasikan bahwa rata-rata kesalahan prediksi hanya terpaut sangat kecil dari nilai aktualnya. Performa ini diperkuat oleh nilai koefisien determinasi  $R^2$  yang mencapai 0,996389, yang berarti model mampu menjelaskan 99,63% varians dari data nilai tukar MYR/IDR.

TABEL IV  
HASIL EVALUASI MODEL RNN

Metrik Evaluasi	Nilai
MSE	196.527592
MAE	10.541243
MAPE	0,2909%
$R^2$	0,996389

Secara keseluruhan, kombinasi metrik MSE sebesar 196,527 dan MAE sebesar 10,541 menunjukkan bahwa optimasi PSO berhasil menemukan parameter bobot RNN yang optimal untuk menekan galat prediksi. Hasil ini membuktikan bahwa arsitektur model yang diusulkan menunjukkan performa prediksi yang sangat baik khususnya pada prediksi nilai tukar MYR/IDR.



Gbr. 6 Hasil Prediksi Nilai Tukar MYR/IDR Menggunakan RNN

Visualisasi hasil prediksi pada Gbr. 6 memperlihatkan perbandingan yang sangat rapat antara nilai aktual (garis biru) dan nilai prediksi (garis oranye) sepanjang periode data validasi. Grafik tersebut menunjukkan bahwa model RNN dengan optimasi PSO mampu mengikuti tren naik dan turunnya nilai tukar MYR/IDR dengan sangat responsif tanpa mengalami gejala *lag* yang signifikan. Titik-titik prediksi terlihat hampir berhimpit dengan data asli, yang mencerminkan kemampuan model dalam menangkap pola non-linier dan volatilitas pasar mata uang secara efektif. Konsistensi jarak antara kedua garis tersebut dari awal tahun 2024 hingga akhir 2025 membuktikan stabilitas model dalam melakukan estimasi jangka pendek.

## V. KESIMPULAN

Penelitian ini berhasil membuktikan bahwa kombinasi metode RNN dengan optimasi PSO mampu menghasilkan model prediksi nilai tukar MYR/IDR yang sangat akurat dan andal. Pendekatan *hybrid* ini secara efektif menjawab celah pada penelitian-penelitian sebelumnya yang belum mengintegrasikan mekanisme optimasi *hyperparameter* pada model RNN, sehingga menghasilkan performa prediksi yang lebih baik dibandingkan pendekatan konvensional. Model yang dibangun menunjukkan tingkat akurasi yang sangat tinggi, sebagaimana tercermin dari hasil evaluasi yang

diperoleh, yaitu nilai MAPE sebesar 0,2909% dan koefisien determinasi  $R^2$  sebesar 0,9964. Angka-angka tersebut mengindikasikan bahwa model mampu menjelaskan hampir seluruh variasi pergerakan nilai tukar aktual dengan rata-rata kesalahan prediksi yang sangat kecil. Hasil prediksi pun hampir sepenuhnya mengikuti pola pergerakan nilai tukar aktual, termasuk pada periode yang sangat fluktuatif, membuktikan bahwa model mampu menangkap dinamika pasar valuta asing secara responsif dan konsisten.

Dengan demikian, model RNN dengan optimasi menggunakan PSO yang diusulkan dalam penelitian ini tidak hanya bernilai secara ilmiah, tetapi juga memiliki relevansi praktis yang tinggi sebagai alat bantu prediksi nilai tukar. Ke depannya, pendekatan ini berpotensi dikembangkan lebih lanjut untuk mendukung pengambilan keputusan yang lebih baik bagi para pelaku pasar, investor, maupun pemangku kebijakan ekonomi, khususnya dalam konteks hubungan ekonomi bilateral antara Indonesia dan Malaysia.

#### UCAPAN TERIMA KASIH

Ucapan terima kasih yang tulus penulis tujukan kepada dosen pembimbing atas dedikasi waktu, ilmu, serta bimbingannya yang luar biasa. Masukan dan kritik yang diberikan selama ini sangat membantu penulis dalam mengembangkan wawasan serta menyelesaikan seluruh tahapan penelitian ini..

#### REFERENSI

- [1] Putu Krishna Candrawinata dan I Nyoman Wahyu Widiana, "Determinants Analysis Of Indonesia's Foreign Exchange Reserves In 1990-2023," *IJEMA*, vol. 2, no. 3, hlm. 239–251, Mei 2025, doi: 10.61132/ijema.v2i3.722.
- [2] A. I. Rahutami, "Menjaga Volatilitas Nilai Tukar: Faktor Pendukung Pengembangan Bisnis di ASEAN," *Kinerja: Jurnal Ekonomi dan Bisnis*, vol. 12, no. 1, hlm. 77-93, 2008.
- [3] M. W. Tirta, M. K. Nursyarif, I. Hasmadi, F. Akbar, dan F. Yulianto, "Prediksi Kurs Mata Uang Rupiah Terhadap Ringgit Malaysia Menggunakan Algoritma Backpropagation," *Jurnal Penelitian Teknik Informatika, Manajemen Informatika dan Sistem Informasi*, vol. 11, no. 1, hlm. 25–33, Apr 2024, doi: 10.31294/inf.v11i1.20946.
- [4] E. C. Wibowo dan A. D. Cahyono, "Analisis Perbandingan Algoritma Regresi Linier dengan Neural Network untuk Prediksi Harga Saham," *Sistemasi: Jurnal Sistem Informasi*, vol. 14, no. 4, hlm. 1879-1896, 2025.
- [5] N. Birdi, P. K. Sarangi, T. Singla, A. K. Sahoo, dan G. B. Subudhi, "Forex trend analysis using RNN and LSTM models: Predictive analytics through neural networks," *2023 International Conference on Computational Intelligence and Sustainable Engineering Solutions (CISES)*. IEEE, hlm. 206–210, Apr 28, 2023. doi: 10.1109/cises58720.2023.10183561.
- [6] R. Sumargo dan I. Wasito, "Deep Learning for Exchange Rate Prediction Within Time Constrains," *Sinkron*, vol. 8, no. 3, hlm. 1259–1271, Jul. 2024, doi: 10.33395/sinkron.v8i3.13633.
- [7] A. Pramuntadi, "Model Prediksi Rentet Waktu Neural Network Berbasis Particle Swarm Optimization untuk Prediksi Harga Saham," *Telematika*, vol. 14, no. 2, hlm. 100-106, 2017.
- [8] A. K. Saputra, R. Y. Endra, dan E. Erlangga, "Optimasi Parameter Neural Network untuk Meningkatkan Efisiensi Pembelajaran Model," *Expert J. Manaj. Sist. Inf. dan Teknol.*, vol. 15, no. 2, hlm. 220, Des 2025, doi: 10.36448/expert.v15i2.4618.
- [9] H. W. Dinara, Y. D. N. Aini, M. V. I. Fajar, P. P. Salsabila, dan H. N. Fanis, "Perdagangan Internasional: Peran Permintaan dan Penawaran dalam Menentukan Nilai Tukar," *Jurnal Penelitian Multidisiplin Terpadu*, vol. 9, no. 5, hlm. 233-242, 2025.
- [10] Arwansyah, Suryani, Hasyrif SY, Usman, Ahyuna, dan S. Alam, "Time Series Forecasting Menggunakan Deep Gated Recurrent Units," *Digital Transformation Technology (Digitech)*, vol. 4, no. 1, hlm. 410-416, 2024.
- [11] S. K. N. A. Putri, I. Jumiati, I. Sulistia, N. A. B. Saputra, dan N. Wiranda, "Penerapan Hyperparameter Tuning pada Model Klasifikasi untuk Prediksi Risiko Penyakit Jantung," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 4, hlm. 1181-1189, 2025.
- [12] A. Rofii dan E. L. Putri, "Tinjauan Komprehensif Jaringan Syaraf Tiruan RNN: Karakteristik, dan Aplikasi dalam Peramalan Energi Bangunan Gedung," *Jurnal Kajian Teknik Elektro*, vol. 9, no. 2, hlm. 1-11, 2024.
- [13] M. Juneja dan S. K. Nagar, "Particle swarm optimization algorithm and its parameters: A review," *2016 International Conference on Control, Computing, Communication and Materials (ICCCCM)*. IEEE, hlm. 1–5, Okt 2016. doi: 10.1109/iccccm.2016.7918233.
- [14] A. Kaveh, "Particle Swarm Optimization," *Advances in Metaheuristic Algorithms for Optimal Design of Structures*. Springer International Publishing, hlm. 9–40, 2014. doi: 10.1007/978-3-319-05549-7\_2.
- [15] H. Nuha, "Mean Squared Error (MSE) dan Penggunaannya," *JAPATUM*, vol. 3, no. 4, Okt 2025, doi: 10.59328/japatum.2024.3.4.107.
- [16] A. Deolika, L. N. Hasinah, M. Iqbal, dan M. N. Aripin, "PREDIKSI KEHILANGAN FUNGSI SUNGAI KAPUAS DENGAN METODE LSTM," *Com, Engine, Sys, Sci*, vol. 6, no. 3, hlm. 1192–1203, Des 2025, doi: 10.46576/djtechno.v6i3.7736.
- [17] B. W. Pangesti dan A. Fahrurrozi, "Prediksi Nilai Tukar US Dollar dan Ringgit Malaysia Terhadap Rupiah Menggunakan Metode Long Short Term Memory," *jukomtek*, vol. 2, no. 1, hlm. 1–7, Jul. 2023, doi: 10.58290/jukomtek.v2i1.82.
- [18] K. Syaban dan Mardawati, "Evaluasi Model Ensemble Learning pada Identifikasi Faktor Risiko Diabetes Mellitus," *JATI*, vol. 15, no. 2, hlm. 121–130, Sep. 2025, doi: 10.34010/jati.v15i2.16238.
- [19] M. M. Al Haromainy, D. A. Prasetya, dan A. P. Sari, "Improving Performance of RNN-Based Models With Genetic Algorithm Optimization For Time Series Data," *TIERS*, vol. 4, no. 1, hlm. 16–24, Jun. 2023, doi: 10.38043/tiers.v4i1.4326.
- [20] I. A. Taufik, T. Trimono, dan A. Muhaimin, "Prediction of The Islamic Stock Price Index and Risk of Loss Using The Long Short-Term Memory (LSTM) and Value At Risk (VaR)," *IJDASEA Int'l J. of DA. DE. DA.*, vol. 4, no. 01, hlm. 12–22, Mei 2024, doi: 10.33005/ijdasea.v4i01.16.
- [21] A. Muhaimin, D. D. Prastyo, dan H. Horng-Shing Lu, "Forecasting with Recurrent Neural Network in Intermittent Demand Data," *2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*. IEEE, hlm. 802–809, Jan 28, 2021. doi: 10.1109/confluence51648.2021.9376880.
- [22] M. Idhom, A. Fauzi, T. Trimono, dan P. Riyantoko, "Time Series Regression: Prediction of Electricity Consumption Based on Number of Consumers at National Electricity Supply Company," *TEM Journal*, hlm. 1575–1581, Agu 2023, doi: 10.18421/tem123-39.
- [23] R. Ardi, M. Idhom, dan K. M. Hindrayani, "Effectiveness of Extreme Learning Machine in Online Payment Transaction Fraud Detection," *bit-Tech*, vol. 8, no. 2, hlm. 1594–1604, Des 2025, doi: 10.32877/bt.v8i2.3005.
- [24] A. J. Dautel, W. K. Hårdle, S. Lessmann, dan H.-V. Seow, "Forex exchange rate forecasting using deep recurrent neural networks," *Digit Finance*, vol. 2, no. 1–2, hlm. 69–96, Mar 2020, doi: 10.1007/s42521-020-00019-x.
- [25] A. Pranolo, Y. Mao, A. P. Wibawa, A. B. P. Utama, dan F. A. Dwiyanto, "Optimized Three Deep Learning Models Based-PSO Hyperparameters for Beijing PM2.5 Prediction," *arXiv*, 2023, doi: 10.48550/ARXIV.2306.07296.
- [26] X. Zeng, C. Liang, Q. Yang, F. Wang, dan J. Cai, "Enhancing stock index prediction: A hybrid LSTM-PSO model for improved forecasting accuracy," *PLoS ONE*, vol. 20, no. 1, hlm. e0310296, Jan 2025, doi: 10.1371/journal.pone.0310296.
- [27] F. Liu, P. Qin, J. You, dan Y. Fu, "Sparrow Search Algorithm-Optimized Long Short-Term Memory Model for Stock Trend Prediction," *Computational Intelligence and Neuroscience*, vol. 2022, hlm. 1–11, Agu 2022, doi: 10.1155/2022/3680419.
- [28] H. Ding dkk., "EUR/USD Exchange Rate Forecasting incorporating Text Mining Based on Pre-trained Language Models and Deep Learning Methods," 2024, arXiv. doi: 10.48550/ARXIV.2411.07560.