

Peramalan Nilai Tukar Mata Uang Menggunakan Metode Nonlinear Autoregressive Exogenous Neural Network

Cecep Jamaludin^{1*}, Wina Witanti², Melina³

^{1,2,3} Universitas Jenderal Achmad Yani, Indonesia

Jl. Terusan Jend. Sudirman, Cimahi, Jawa Barat, Kota Cimahi, Jawa Barat, Indonesia

*Corresponding author e-mail : cecepjamaludin20@if.unjani.ac.id

ABSTRAK

Nilai tukar mata uang sering kali mengalami fluktuasi atau naik turun terhadap mata uang negara lain, terutama Great Britain Pound (GBP) terhadap Indonesian Rupiah (IDR). Perubahan nilai tukar mata uang dipengaruhi oleh berbagai faktor yang berhubungan langsung (endogen) dan faktor yang tidak berhubungan langsung (eksogen). Ketika nilai fluktuasi nilai tukar mata uang melebihi ambang batas tertentu dapat berdampak negatif pada perdagangan internasional dan menghambat pertumbuhan ekonomi negara. Penelitian ini mengkaji penggunaan metode Nonlinear Autoregressive Exogenous Neural Network (NARX-NN) untuk meramalkan nilai tukar mata uang GBP/IDR dengan menambahkan faktor eksternal seperti inflasi, suku bunga, ekspor, dan jumlah uang beredar pada model peramalan dengan tujuan untuk meningkatkan keakuratan peramalan nilai tukar mata uang dengan menggunakan metode NARX-NN. Hasil dari penelitian ini menunjukkan bahwa dengan memasukkan faktor-faktor yang mempengaruhi fluktuasi nilai tukar mata uang, diperoleh hasil peramalan yang lebih baik yaitu nilai Mean Absolute Error (MAE) sebesar 33.28, Root Mean Square Error (RMSE) sebesar 53.53, dan R-Squared (R^2) sebesar 0.99 dengan pembagian data sebanyak 80/20. Diharapkan, hasil penelitian ini dapat menjadi referensi bagi investor, akademisi, dan masyarakat dalam memaksimalkan keuntungan dan meminimalisir risiko kerugian pada kurs mata uang GBP/IDR.

Kata kunci : endogen; eksogen; nilai tukar; peramalan; NARX-NN.

ABSTRACT

Currency exchange rates often fluctuate or rise and fall against other countries' currencies, especially the Great Britain Pound (GBP) against the Indonesian Rupiah (IDR). Changes in currency exchange rates are influenced by various factors that are directly related (endogenous) and factors that are not directly related (exogenous). When the value of currency exchange rate fluctuations exceeds a certain threshold, it hurts international trade and hampers the country's economic growth. This research examines the use of the Nonlinear Autoregressive Exogenous Neural Network (NARX-NN) method to forecast the GBP/IDR currency exchange rate by adding external factors such as inflation, interest rates, exports, and money supply to the forecasting model to improve the accuracy of forecasting currency exchange rates using the NARX-NN method. The results of this study show that by including factors that affect currency exchange rate fluctuations, better forecasting results are obtained, namely the Mean Absolute Error (MAE) value of 33.28, Root Mean Square Error (RMSE) of 53.53, and R-Squared (R^2) of 0.99 with a data division of 80/20. It is hoped that this research can be a reference for investors, academics, and the public in maximizing profits and minimizing the risk of loss on the GBP/IDR currency exchange rate.

Keywords: endogenous; exogenous; exchange rate; forecasting; NARX-NN.

I. PENDAHULUAN

Mata uang rupiah diperlukan sebagai alat pembayaran yang sah dalam kegiatan ekonomi nasional untuk kesejahteraan sosial seluruh warga negara Indonesia [1]. Penukaran mata uang ke dalam mata uang negara tertentu merupakan salah satu

kegiatan ekonomi yang perlu dilakukan oleh negara atau yang disebut dengan pasar valuta asing [2][3]. Penukaran mata uang memiliki dampak besar pada perekonomian, perdagangan, dan investasi antara negara. Fluktuasi nilai tukar mata uang mengacu pada perubahan harga mata uang suatu negara terhadap

mata uang negara lain dalam kurun waktu tertentu. Fluktuasi dapat memberikan dampak yang signifikan terhadap perekonomian suatu negara. Fluktuasi nilai tukar rupiah dapat menimbulkan risiko karena risiko semakin meningkat seiring dengan meningkatnya fluktuasi. Hal ini dapat mengakibatkan keuntungan atau kerugian [4]. Nilai tukar mata uang juga dapat mempengaruhi berbagai aspek perekonomian [5] seperti inflasi dan krisis ekonomi, sehingga nilai tukar mata uang perlu diramalkan untuk membantu pemerintah atau bank sentral dalam mengendalikan pergerakan nilai tukar dan mengurangi dampak negatif yang mungkin terjadi [6]. Selain itu, ketika nilai fluktuasi nilai tukar melebihi ambang batas tertentu, maka hal tersebut juga akan mengancam perdagangan internasional serta mengganggu pertumbuhan ekonomi negara [7].

Nilai tukar mata uang GBP/IDR mengalami 5 kali penurunan dan 7 kali kenaikan pada periode Januari hingga Agustus 2023. Tercatat pada bulan Januari, Februari, April, Agustus, dan September 2023 terjadi penurunan sebesar 2,04%, 1,43%, 1,20%, 0,09%, dan 2,05%. Sedangkan pada bulan Maret, Mei, Juni, Juli, Oktober, November, dan Desember 2023 terjadi peningkatan sebesar 1,79%, 0,65%, 3,48%, dan 0,68%, yang sebagian besar dipengaruhi oleh faktor endogen dan faktor eksogen. Faktor endogen adalah faktor yang secara langsung mempengaruhi nilai tukar mata uang GBP/IDR [8]. Faktor eksogen adalah faktor yang secara tidak langsung mempengaruhi nilai tukar mata uang GBP/IDR [9].

Variabel ekonomi seperti jumlah uang beredar yang berlebihan dapat memicu depresiasi mata uang rupiah karena kenaikan harga barang domestik, yang disebabkan oleh tekanan permintaan yang berlebihan terhadap barang dan jasa dapat mengakibatkan inflasi [10]. Tingginya tingkat inflasi berdampak negatif pada nilai tukar rupiah karena barang-barang ekspor menjadi lebih mahal, sehingga mengurangi daya saing produk di pasar internasional [11], dan meningkatkan permintaan impor dapat melemahkan nilai tukar rupiah karena meningkatnya permintaan mata uang asing [12][13].

Selain itu, peningkatan nilai ekspor dapat memperkuat pendapatan dan permintaan mata uang negara tersebut, yang pada akhirnya dapat memperkuat nilai tukar mata uang dalam jangka panjang [14]. Suku bunga yang tinggi memiliki dampak yang signifikan karena dapat menarik investor asing untuk membeli aset dengan imbal hasil yang lebih tinggi sehingga meningkatkan permintaan mata uang dan nilai tukar, sedangkan suku bunga yang rendah dapat menurunkan permintaan mata uang dan nilai tukar [12][14].

Nilai tukar mata uang GBP/IDR memiliki kompleksitas yang tinggi [10]. NARX-NN dapat

menangkap pola nonlinier [15], dan dinamis pada data dan berkontribusi dalam pengembangan metode peramalan nilai tukar mata uang yang dapat digunakan oleh para pelaku pasar forex [16]. Selain itu, NARX-NN menghitung nilai *output* berdasarkan nilai *input* dan *output* yang tertunda [17]. Model NARX-NN dengan model Autoregressive Integrated Moving Average (ARIMA) sebagai model statistik acuan menunjukkan bahwa model NARX-NN memiliki kinerja yang lebih baik daripada model ARIMA dalam hal akurasi peramalan dan kestabilan [18]. Peramalan variabel nilai tukar dengan model NARX-NN terbaik dan menggunakan hasil peramalan variabel eksogen sebagai *input* [19].

Peramalan nilai tukar mata uang sangat diperlukan di masa depan [20], dengan harapan dapat membantu para pelaku pasar, seperti investor dapat memahami perdagangan yang tepat pada waktu yang tepat dan mendapatkan lebih banyak keuntungan dengan melakukan analisis pasar valuta asing yang akurat [21]. Dari sudut pandang pemerintah, perkiraan nilai tukar yang akurat memberikan dasar yang kuat untuk departemen administrasi yang relevan, membantu penyesuaian alokasi sumber daya pemerintah, mengurangi tekananeкономи yang disebabkan oleh fluktuasi nilai tukar, dan menghasilkan keuntungan yang signifikan [22].

Peramalan nilai tukar mata uang tidak selalu dapat diandalkan dengan menggunakan model tradisional, karena pasar seringkali melibatkan kompleksitas dan non linieritas [23]. Seperti pada penelitian [17] hanya menggunakan beberapa variabel berupa harga, pembukaan, tertinggi, dan terendah USD serta rata-rata bergerak CHF sebagai variabel eksogen dalam model NARX sehingga kurang merepresentasikan hasil prediksi yang akurat. Penelitian [19] melakukan peramalan nilai tukar rupiah terhadap Dolar AS menghasilkan model terbaik yang diperoleh adalah NARXNN dengan R^2 sebesar 96.39%. Penelitian nilai tukar France Swiss terhadap Leu Rumania [17] menggunakan data historis nilai tukar yang mencakup 2 tahun dan *input* eksogen nilai *open*, *high*, dan *low* [8] untuk melatih dan menguji model NARX [24]. Pada penelitian ini NARX-NN digunakan untuk meramalkan nilai tukar mata uang GBP/IDR [25] dengan faktor endogen yang digunakan adalah data *time series* nilai tukar GBP/IDR [26], dan faktor eksogen seperti data pembukaan, tertinggi, terendah, serta penambahan variabel ekonomi [10], seperti inflasi, jumlah uang beredar, ekspor, suku bunga dengan penggunaan data mencakup periode 13 tahun (2010- 2023).

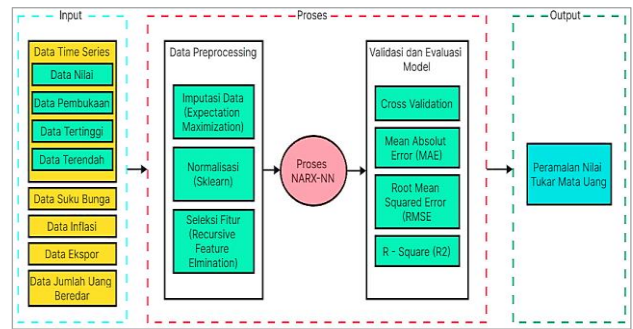
II. METODE

Pada penelitian ini, proses *preprocessing* data dilakukan untuk memeriksa ada tidaknya *outlier* dan data yang hilang [27], dengan menggunakan

Expectation Maximization (EM) untuk mengatasi *missing value* agar menghasilkan *dataset* awal yang lengkap dan lengkap, menormalisasi data dengan *sklearn*, dan menggunakan *Recursive Feature Elimination* (RFE) untuk menyeleksi fitur-fitur yang penting. Selain itu, penelitian ini melakukan validasi sistem dengan menggunakan *k-fold cross-validation* untuk meningkatkan keandalan hasil peramalan.

Dataset yang digunakan adalah data *time series* nilai tukar mata uang GBP/IDR serta data pembukaan, tertinggi, terendah dan variabel ekonomi yang ditambahkan. Penggunaan data ini mencakup periode 2010 - 2023. Tahap pertama data diolah pada tahap *preprocessing* data. Pada tahap ini dilakukan dengan beberapa cara seperti imputasi, seleksi fitur, dan *sklearn*. Imputasi menggunakan IBM SPSS Statistics. Seleksi fitur dan *sklearn* menggunakan Google Colab. Data dibagi menjadi data latih dan data uji. Kemudian data tersebut diolah ke dalam sistem NARX-NN. Setelah diperoleh hasil peramalan dan nilai aktual, selanjutnya dilakukan proses validasi dan evaluasi. Setelah diperoleh nilai validasi dan evaluasi,

peramalan nilai tukar telah berhasil didapatkan. Tahapan penelitian ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. PENGUMPULAN DATA

Data primer diperoleh dengan melakukan wawancara di Bank Indonesia, sedangkan data sekunder adalah data yang diperoleh secara *online* dari situs resmi Bank Indonesia (<https://www.bi.go.id/>) dan Badan Pusat Statistik (<https://www.bps.go.id/>). Data yang dikumpulkan dalam penelitian ini ditunjukkan pada Tabel 1.

Tabel 1. Contoh Pengumpulan Data yang diperoleh

Tanggal	Nilai	Pembukaan	Tertinggi	Terendah	Inflasi	Jumlah Uang Beredar	Ekspor	Suku Bunga
10-Okt-2023	19.324,30	19.202,20	19.343,00	19.181,60	-	-	-	-
09-Okt-2023	19.190,60	19.085,60	19.212,40	19.041,90	-	-	-	-
08-Okt-2023	-	-	-	-	-	-	-	-
07-Okt-2023	-	-	-	-	-	-	-	-
06-Okt-2023	19.097,40	19.037,80	19.141,80	18.896,70	-	-	-	-
05-Okt-2023	19.028,60	18.969,30	19.045,60	18.905,10	-	-	-	-
04-Okt-2023	18.950,00	18.811,30	19.034,20	18.793,40	-	-	-	-
03-Okt-2023	18.806,80	18.778,90	18.859,60	18.754,80	-	-	-	-
02-Okt-2023	18.763,50	18.856,70	18.988,80	18.769,60	-	-	-	-
01-Okt-2023	-	-	-	-	-	-	-	-
30-Sep-2023	-	-	-	-	-	-	-	-
29-Sep-2023	18.844,40	18.934,40	18.970,00	18.823,40	2,28	8440034,10	20746,50	-
28-Sep-2023	18.923,70	18.833,50	18.974,80	18.809,50	-	-	-	-
27-Sep-2023	18.825,90	18.832,70	18.882,10	18.793,90	-	-	-	-
26-Sep-2023	18.826,70	18.801,90	18.890,10	18.791,80	-	-	-	-
25-Sep-2023	18.798,80	18.828,20	18.875,30	18.778,00	-	-	-	-
24-Sep-2023	-	-	-	-	-	-	-	-
23-Sep-2023	-	-	-	-	-	-	-	-
22-Sep-2023	18.809,80	18.912,80	18.915,40	18.803,60	-	-	-	-
21-Sep-2023	18.895,90	18.992,80	19.003,50	18.813,60	-	-	-	-
20-Sep-2023	18.978,90	19.058,90	19.105,80	18.965,80	-	-	-	5,76

B. PENGOLAHAN DATA

Pada tahap ini, data yang diperoleh dari pengumpulan data akan diolah. Data tersebut dibagi menjadi dua jenis, yaitu *data training* dan *data testing*. Pengolahan data dilakukan dengan beberapa tahapan:

1. Imputasi data dilakukan dengan menggunakan *Expectation Maximization* (EM) dengan persamaan (1 - 2) [28]

$$Q(\theta | \theta(t)) = \sum Z P(Z | X, \theta(t)) \log P(X, Z | \theta) \quad (1)$$

$$\theta = \operatorname{argmax}_{\theta} \sum \log(\pi) \quad (2)$$

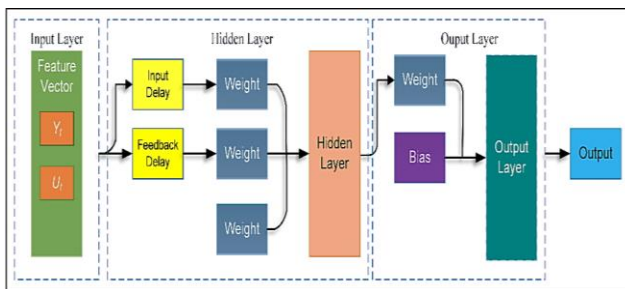
$Q(\theta | \theta(t))$ adalah fungsi ekspektasi yang merupakan ekspektasi dari *log-likelihood* yang dikondisikan θ adalah parameter model yang akan diestimasi, dan $\theta(t)$ adalah nilai parameter pada iterasi ke- t . Z adalah variabel tersembunyi. X adalah data observasi. $P(Z | X, \theta(t))$ adalah distribusi posterior dari variabel tersembunyi Z berdasarkan data saat ini dan parameter $\theta(t)$. $P(X, Z | \theta)$ adalah fungsi *likelihood* dari data

dan variabel tersembunyi berdasarkan parameter t .

2. Normalisasi, teknik normalisasi ini menggunakan fungsi *sklearn* yang merupakan sebuah *library* Python untuk melakukan *machine learning*. *Library* ini berisi fungsi-fungsi yang memungkinkan untuk mengacak kumpulan data dan membaginya menjadi data pelatihan dan pengujian.
3. Seleksi Fitur, menggunakan teknik *Recursive Feature Elimination* (RFE). Teknik RFE dapat membantu mengurangi dimensi data dan meningkatkan akurasi dan keandalan model NARX-NN.

C. ARSITEKTUR NARX-NN

Dalam proses pengembangan model NARX-NN, beberapa proses dapat dilihat pada Gambar 2.



Gambar 2. Proses NARX-NN

Input layer merupakan lapisan pertama dalam *neural network* dan berperan sebagai tempat untuk menerima data *input* atau fitur dari *dataset*. Struktur data vektor fitur pada *input layer* yang akan masuk ke dalam arsitektur *neural network* merupakan data mentah yang akan diproses oleh *neural network* dan digunakan sebagai *input* untuk model NARX-NN. *Feature vector* merupakan data yang telah diubah menjadi bentuk *vektor* yang dapat diproses oleh *neural network*. *Feature vector* merupakan representasi numerik dari data *time series* nilai tukar GBP/IDR dan variabel ekonomi. *Feature vector* dibentuk dengan menggabungkan nilai dari 7 variabel *input* pada setiap titik waktu, seperti nilai tukar, pembukaan, tertinggi, terendah, inflasi, tingkat suku bunga, ekspor, dan jumlah uang beredar. Setiap vektor fitur memiliki panjang 8 dan menciptakan vektor numerik yang menggambarkan keadaan pada suatu titik waktu. Jaringan syaraf menggunakan vektor fitur ini untuk mengidentifikasi pola dan hubungan antar variabel, yang digunakan untuk meramalkan nilai tukar GBP/IDR di masa mendatang. Persamaan NARX-NN dengan rumus (3) [29].

$$y(t) = F(y(t-1), y(t-2), \dots, y(t-n) \times u(t-1), u(t-2), \dots, u(t-m)) \quad (3)$$

$y(t)$ adalah faktor target yang akan diramalkan pada waktu t . F adalah fungsi non-linear yang dipelajari

oleh jaringan syaraf. $y(t-1), y(t-2), \dots, y(t-n)$ adalah nilai target pada waktu sebelumnya (endogen). $u(t-1), u(t-2), \dots, u(t-m)$ adalah nilai-nilai faktor *input* lain yang mempengaruhi target (eksogen). n dan m adalah jumlah penundaan yang digunakan untuk input endogen dan eksogen, masing-masing.

Lapisan tersembunyi adalah lapisan antara lapisan *input* dan lapisan *output*. Lapisan ini mengambil data *input* dan melakukan operasi matematika yang kompleks, seperti transformasi non-linear, untuk mengekstrak pola atau hubungan yang kompleks dalam data. Lapisan *output* adalah lapisan terakhir dalam jaringan saraf dan menghasilkan ramalan atau hasil dari model. *Output* dari lapisan ini dapat berupa nilai tukar mata uang yang diprediksi dalam konteks NARX-NN.

D. PENGEMBANGAN SISTEM

Sistem ini dibangun berdasarkan integrasi dari tahapan-tahapan yang telah dilakukan sebelumnya. Tahapan-tahapan dalam penelitian ini menggunakan IBM SPSS Statistics dan bahasa pemrograman Python. IBM SPSS Statistics digunakan untuk melakukan proses imputasi data. Bahasa pemrograman Python melalui Google Colab untuk melakukan proses normalisasi dengan fungsi *sklearn*, seleksi fitur dengan teknik RFE, dan pembangunan sistem NARX-NN.

E. VALIDASI DAN EVALUASI

Pada tahap ini dilakukan uji validasi dan evaluasi terhadap sistem NARX-NN dengan melakukan beberapa teknik antara lain sebagai berikut:

1. *K-Fold Cross Validation*, teknik ini membagi data menjadi k bagian yang sama, kemudian dilatih dan diuji pada model sebanyak k kali. Pada setiap iterasi, sebagian data digunakan sebagai data *testing* dan sebagian lagi digunakan sebagai data *training*. Hasil evaluasi dari setiap iterasi kemudian dihitung dan dirata-ratakan untuk mendapatkan hasil evaluasi akhir.
2. *Mean Absolute Error* (MAE) berfungsi sebagai ukuran untuk menilai keefektifan model regresi. MAE mengukur rata-rata perbedaan absolut antara nilai prediksi model dengan nilai aktual dalam data. MAE dengan rumus (4) [20].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}| \quad (4)$$

y_i adalah nilai sebenarnya. \hat{y} adalah nilai peramalan. n adalah Jumlah observasi/baris

3. *Root Mean Square Error* (RMSE) berfungsi sebagai metrik untuk menilai keefektifan model. RMSE mengukur perbedaan kuadrat rata-rata

akar antara nilai prediksi model dan nilai aktual dalam data. RMSE dihitung dengan rumus (5) [20].

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y})^2}{n}} \quad (5)$$

y_i adalah nilai sebenarnya. \hat{y} adalah nilai yang diramalkan. n adalah jumlah observasi/baris.

Koefisien Determinasi (R^2) merupakan salah satu metrik evaluasi yang digunakan untuk mengukur seberapa besar faktor independen dapat menjelaskan variasi faktor dependen. R^2 dengan rumus (6) [30].

$$R^2 = 1 - \frac{SS\ Error}{SS\ Total} = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (6)$$

y_i adalah pengamatan respon ke- i . \hat{y} adalah ramalan respon ke- i . \bar{y} adalah rata-rata.

III. HASIL DAN PEMBAHASAN

Berikut ini merupakan hasil dan pembahasan dari penelitian ini. Hasil pembahasan terdiri dari pengolahan data dan sistem NARX Neural Network.

Tabel 2. Dataset Expectation Maximization

Tanggal	Nilai	Pembukaan	Tertinggi	Terendah	Inflasi	Jumlah Uang Beredar	Ekspor	Suku Bunga
24-Nov-23	19610,30	19493,50	19638,40	19484,90	2,52	8286806,89	19732,58	3,51
23-Nov-23	19488,80	19454,70	19543,30	19447,60	2,41	8260593,25	19825,82	6,00
22-Nov-23	19450,00	19361,00	19555,50	19343,20	2,44	8286008,19	19791,35	3,52
21-Nov-23	19350,90	19317,10	19434,50	19249,70	2,36	8280909,58	19820,92	3,57
20-Nov-23	19306,20	19297,50	19408,90	19185,80	2,32	8277865,92	19833,30	3,60
19-Nov-23	20045,10	20060,78	20157,75	19962,07	2,52	8248468,00	19516,50	3,76
18-Nov-23	20044,15	20059,82	20156,79	19961,12	2,52	8247193,23	19515,22	3,76
17-Nov-23	19302,10	19299,10	19314,60	19172,70	2,32	8273344,45	19828,91	3,61
16-Nov-23	19278,90	19294,50	19364,40	19236,90	2,29	8270415,39	19833,47	3,63
...
06-Jan-10	14815,10	14893,80	14949,60	14717,80	5,79	1793482,20	13187,63	7,27
05-Jan-10	14910,10	15027,10	15086,60	14870,50	5,79	1784017,10	13138,81	7,33
04-Jan-10	15042,60	15189,80	15274,50	14982,10	5,80	1774333,41	13075,76	7,40
03-Jan-10	15235,32	15216,66	15311,31	15146,63	6,02	1787962,29	13024,31	7,22
02-Jan-10	15240,70	15219,00	15240,70	15207,60	6,03	1786865,60	13020,94	7,22

Tabel 2 menghasilkan data yang lengkap dengan puncak data pada akhir pekan. Kemudian proses dilanjutkan dengan normalisasi data menggunakan fungsi *sklearn* pada bahasa pemrograman python. Fungsi *sklearn* ini membantu dalam proses penanganan data, pembelajaran, dan analisis data untuk menghasilkan analisis data yang baik. Fungsi *sklearn* ini juga akan menjadi *training set* dan *test set* dengan menggunakan fungsi *train test split* dari scikit-learn. Selanjutnya data tersebut dianalisis untuk pemilihan fitur yang akan diperhitungkan dalam penelitian ini. Pemilihan fitur ini akan dilakukan dengan menggunakan RFE. Metode ini bekerja dengan mengeliminasi fitur secara iteratif berdasarkan kontribusinya terhadap kinerja model. RFE dapat mengurangi beban komputasi yang

A. PENGOLAHAN DATA

Pengolahan data pada dataset dilakukan untuk mengatasi imputasi, normalisasi, dan seleksi fitur. *Dataset* didapatkan dari sumber-sumber yang telah disebutkan di atas yang kemudian harus diolah terlebih dahulu untuk mendapatkan hasil yang tepat. *Dataset* ini memiliki kekurangan data pada akhir pekan, sehingga dilakukan imputasi untuk menghasilkan dataset awal yang lengkap.

Dataset yang digunakan adalah data *time series* nilai, *open*, *high*, *low*, inflasi, suku bunga, ekspor, dan jumlah uang beredar dengan jumlah data sebanyak 5086 data. Penggunaan EM diawali dengan melakukan inisialisasi parameter model secara acak atau menggunakan nilai awal yang wajar dengan membatasi jumlah iterasi atau perubahan nilai parameter yang signifikan.

Selanjutnya, nilai ekspektasi dari variabel tersembunyi (tidak teramati) berdasarkan data yang diamati dihitung dan kemudian parameter model diperbarui dengan memaksimalkan nilai ekspektasi yang telah dihitung. Terakhir, langkah-langkah tersebut diulang sampai konvergensi tercapai. Data yang dihasilkan pada langkah ini ditunjukkan pada Tabel 2.

diperlukan untuk melatih dan menjalankan model dengan mengeliminasi fitur-fitur yang kurang penting. *Pseudocode* untuk proses *sklearn* dan RFE dapat dilihat pada Gambar 3 dan Gambar 4.

```
# Skala data
scaler = StandardScaler()
train_data_scaled =
scaler.fit_transform(train_data[features + [target_col]])
test_data_scaled =
scaler.transform(test_data[features + [target_col]])
```

Gambar 3. Pseudocode Sklearn

```

from sklearn.feature_selection import
RFE
from sklearn.linear_model import
LinearRegression
model = LinearRegression()
rfe = RFE(model,
n_features_to_select=5)

# Melatih RFE pada data latih
features_train_rfe =
rfe.fit_transform(features_train_sca
led, target_train)

# Mendapatkan indeks fitur yang
dipilih
selected_feature_indices =
rfe.get_support(indices=True)

# Menampilkan nama fitur yang dipilih
selected_features =
features_train.columns[selected_featu
re_indices]
print("Selected Features:",
selected_features)

```

Gambar 4. Pseudocode RFE

Pseudocode pada Gambar 3 dan Gambar 4 ini menskalakan data latih dan uji dengan `StandardScaler` dari `sklearn` untuk memastikan fitur-fitur memiliki mean 0 dan standar deviasi 1. Ini penting untuk kinerja algoritma pembelajaran mesin karena membantu konvergensi model seperti *regresi* logistik dan jaringan saraf lebih cepat dan efisien, serta mencegah dominasi fitur dengan skala lebih besar selama pelatihan. Selanjutnya, kode menggunakan RFE dengan `LinearRegression` untuk memilih fitur-fitur penting dari data latih. Model `LinearRegression` diinisiasi dan RFE diatur untuk mempertahankan lima fitur teratas. Setelah pelatihan pada data latih yang telah diskalakan (`features_train_scaled` dan `target_train`), fitur dipilih diambil dengan `get_support(indices=True)` dan nama-nama fitur yang dipilih ditampilkan. Proses ini membantu mengidentifikasi fitur yang paling relevan, sehingga meningkatkan kinerja dan interpretabilitas model dengan mengeliminasi fitur yang kurang penting. Data yang dihasilkan pada langkah ini ditunjukkan pada Tabel 3.

Tabel 3. Dataset Sklearn dan Recursive Feature Elimination

Tanggal	Nilai	Pembukaan	Tertinggi	Terendah	Inflasi	Jumlah Uang Beredar
31-Mar-17	16599.8	16734.8	16567.0	3.61	5017643.55	16729.5
29-Ags-10	13996.1	14051.0	13927.1	5.32	2133328.47	13940.9
15-Mei-11	13814.3	13935.4	13804.9	5.18	2490167.77	13884.9
06-Nov-21	19350.6	19447.23	19256.1	3.03	7301318.09	19339.96
29-Jun-13	15077.4	15158.3	15074.4	4.76	3458344.93	15106.7
06-Feb-21	19089.66	19186.17	18996.7	3.22	6953307.42	19080.87
05-Mei-23	18454.2	18569.0	18430.3	2.35	8052482.41	18529.7
09-Des-12	15471.2	15534.9	15464.5	5.1	3183053.03	15523.0
02-Des-17	17978.99	18074.97	17892.61	4.03	5472031.25	17978.07
25-Jan-12	13909.5	14106.0	13903.2	5.07	2828157.56	14061.2
14-Apr-20	19559.4	19774.6	19543.0	3.85	6563407.1	19704.5
23-Mei-23	18519.4	18535.8	18410.3	2.18	8061201.91	18462.8
...
23-Okt-11	14119.3	14207.5	14045.9	5.05	2685308.1	14136.5
26-Ags-22	17540.2	17635.8	17383.9	2.04	7733500.17	17403.2
18-Jun-15	21156.8	21194.9	21049.6	5.83	4187985.44	21129.7
07-Ags-13	15971.0	16003.4	15929.9	4.91	3473596.03	15941.8
28-Jul-21	20117.0	20154.8	20056.5	3.4	7145758.65	20131.3

Tabel 3 menunjukkan data setelah fungsi *sklearn* dan RFE sebanyak 4068 data. Model *regresi linier* dipilih sebagai model yang digunakan untuk RFE, kemudian RFE diinisialisasi dengan model *regresi linier* bersama dengan jumlah fitur yang diinginkan untuk dipertahankan. Selanjutnya, RFE dilatih menggunakan fitur yang telah diskalakan serta data target. Dalam pelatihan ini, RFE secara iteratif memilih fitur terbaik dan secara bertahap menghilangkan fitur yang dianggap kurang penting berdasarkan kinerja model *regresi linier*. Setelah proses pelatihan selesai, fitur terbaik dipilih berdasarkan nilai yang dihasilkan oleh objek RFE. Akhirnya diperoleh fitur terpilih, yaitu nilai sebagai

variabel endogen, pembukaan, tertinggi, terendah, inflasi, dan jumlah uang beredar.

B. SISTEM NARX NEURAL NETWORK

Pada konfigurasi sistem NARX-NN yang digunakan, arsitektur Jaringan Syaraf Tiruan (JST) terdiri dari dua lapisan tersembunyi dengan total 16 neuron. Lapisan pertama memiliki 10 neuron, sedangkan lapisan kedua dilengkapi dengan 5 neuron, untuk menghasilkan *output*, digunakan lapisan *Dense* dengan jumlah neuron yang sesuai dengan langkah *output*, yang dalam hal ini adalah 1. *Pseudocode* proses NARX-NN dapat dilihat pada Gambar 5.

```

# Definisikan model NARX
def build_narx_model(input_shape,
                    exog_features, output_steps):
    model = Sequential()

    # Encoder
    model.add(LSTM(10,
                  activation='relu',
                  input_shape=input_shape,
                  return_sequences=True))
    model.add(LSTM(5,
                  activation='relu'))

    # Menggabungkan dengan fitur
    eksogen
    exog_input =
    Input(shape=(exog_features,))
    concatenated =
    concatenate([model.output,
                exog_input])

    # Lapisan Dense untuk prediksi
    output_layer =
    Dense(output_steps)(concatenated)

    model =
    tf.keras.Model(inputs=[model.input,
                           exog_input], outputs=output_layer)
    return model

```

Gambar 5. Pseudocode NARX-NN

Pseudocode Gambar 5 mendefinisikan model NARX-NN menggunakan arsitektur *Long Short Term Memory* (LSTM). Prediksi dilakukan menggunakan lapisan *Dense* dengan jumlah *output* yang sesuai. Proses ini memungkinkan model untuk mempelajari pola kompleks dalam data sambil mempertimbangkan pengaruh fitur eksogen. Hal ini dapat berguna dalam memodelkan hubungan antara data *time series* dengan variabel eksternal yang memengaruhinya. Pelatihan model dilakukan selama 20 *epoch*, dan evaluasi model dilakukan dengan memonitor nilai *loss* pada setiap *epoch*. Proses ini memberikan wawasan yang mendalam tentang kemajuan dan kinerja model selama pelatihan.

Selanjutnya, untuk meningkatkan keandalan dan akurasi estimasi model, metode *K-Fold Cross Validation* diterapkan dengan menggunakan 5 *fold*. Pada tahap evaluasi, hasil yang diperoleh dari metrik kinerja seperti MAE, RMSE, dan R^2 menunjukkan signifikansi yang cukup. Membagi data pelatihan dengan rasio 60/40, 70/30, 80/20, dan 90/10 memberikan hasil evaluasi yang konsisten dan dapat diandalkan, memastikan bahwa model dapat beradaptasi dengan baik terhadap variasi *dataset*.

Proses validasi dan evaluasi ini memberikan gambaran yang komprehensif mengenai kemampuan model dalam menggeneralisasi informasi dari data pelatihan ke data pengujian. Pendekatan ini memungkinkan model dapat dioptimalkan untuk melakukan prediksi secara akurat berdasarkan pola yang ditemukan dalam data. Selain itu, penggunaan berbagai metrik evaluasi memastikan bahwa kinerja model dinilai dari berbagai perspektif, menciptakan pemahaman yang lebih dalam tentang kecocokan model untuk tugas yang diberikan. Hasil peramalan menggunakan NARX-NN dapat dilihat pada Tabel 4.

Tabel 4. Kesimpulan Hasil Validasi dan Evaluasi


Pembagian Data Latih	MAE	RMSE	R^2
60/40	70.46	115.71	0.99
70/30	40.95	66.67	0.99
80/20	33.28	53.53	0.99
90/10	39.31	104.36	0.99

Tabel 4 menunjukkan bahwa pembagian data *training* 80/20 memiliki tingkat kesalahan yang rendah atau dapat dikatakan akurat dibandingkan dengan pembagian data lainnya. Hal ini menunjukkan bahwa model lebih akurat dalam memprediksi nilai target. Selain itu, nilai R^2 yang mendekati 1 mengindikasikan bahwa model sudah cukup baik dalam menjelaskan variasi data.

Model NARX-NN yang diimplementasikan menggunakan *TensorFlow* dan *Keras* memiliki arsitektur yang terdiri dari dua lapisan LSTM pada fase *encoder*, diikuti oleh lapisan *Dense* untuk prediksi. Arsitektur ini membantu model untuk menangkap pola temporal yang kompleks pada data historis nilai tukar GBP/IDR. Pada setiap lapisan LSTM, 10 neuron pada lapisan pertama dan 5 neuron pada lapisan kedua dengan fungsi aktivasi ReLU digunakan. Variabel-variabel eksogen, yaitu pembukaan, tinggi, rendah, inflasi, dan jumlah uang beredar, dimasukkan ke dalam model melalui lapisan *input* eksogen. Model kemudian menggabungkan hasil dari lapisan LSTM dengan *input* eksogen. Hal ini memungkinkan model untuk mengintegrasikan informasi dari kedua sumber data, yaitu data historis dan fitur eksogen. Proses pelatihan model menggunakan fungsi kerugian MAE yang membantu model untuk mengoptimalkan parameter untuk meminimalkan kesalahan prediksi. Teknik *EarlyStopping* diterapkan selama pelatihan untuk menghentikan proses jika tidak ada peningkatan dalam data validasi setelah beberapa *epoch*, mencegah *overfitting*.


Selama k-fold cross validation, data pelatihan dibagi menjadi beberapa lipatan, dan model dilatih dan dievaluasi pada setiap lipatan. Hal ini membantu dalam mengukur konsistensi kinerja model pada berbagai set data validasi. Hasil dari k-fold cross-

validation pada pembagian data pelatihan 80/20 dapat dilihat pada Gambar 6 sampai Gambar 10.



Gambar 6. Fold 1


Gambar 6 menunjukkan hasil pelatihan model dimana *loss training* terus menurun seiring bertambahnya *epoch*, namun *loss validasi* mulai meningkat kembali setelah mencapai titik terendah.



Gambar 7. Fold 2


Pada Gambar 7, terlihat pola yang sedikit berbeda dibandingkan *fold 1* sebelumnya. Meskipun *loss training* terus menurun seiring bertambahnya *epoch*, *loss validasi* juga menurun dan cenderung stabil pada nilai yang rendah. Model mampu mempelajari pola dari data pelatihan dengan baik, sekaligus dapat menggeneralisasi dengan baik pada data validasi yang belum pernah dilihat sebelumnya.

Gap antara *loss training* dan *loss validasi* tidak terlalu besar, menunjukkan tidak ada masalah *overfitting* atau *underfitting* yang parah. Secara keseluruhan, hasil pada *fold 2* ini cukup memuaskan, dengan model mencapai *loss validasi* yang rendah dan stabil setelah beberapa *epoch* pelatihan.




Gambar 8. Fold 3

Pada Gambar 8 *fold 3*, terlihat pola yang mirip dengan *fold 1* sebelumnya, meskipun *loss training* terus menurun dengan baik seiring bertambahnya *epoch*, namun *loss validasi* mulai meningkat kembali setelah mencapai titik terendah sekitar *epoch* ke-6 atau ke-7. Hasil dari ketiga *fold* ini menunjukkan adanya variasi performa model pada subset data yang berbeda, sehingga evaluasi pada seluruh *fold* penting untuk memahami performa model secara keseluruhan.



Gambar 9. Fold 4

Pada Gambar 9 *fold 4*, terlihat pola yang agak berbeda dari *fold-fold* sebelumnya. Baik *loss training* maupun *loss validasi* menurun dengan cepat pada awal *epoch*, yang merupakan tanda positif. Namun, setelah mencapai titik terendah sekitar *epoch* ke-5, *loss validasi* cenderung datar dan tidak mengalami penurunan lebih lanjut. Sementara itu, *loss training* masih terus menurun hingga akhir iterasi. Gap antara *loss training* dan *loss validasi* yang cukup besar pada akhir iterasi menunjukkan model kurang dapat menggeneralisasi dengan baik pada data validasi yang belum pernah dilihat sebelumnya.

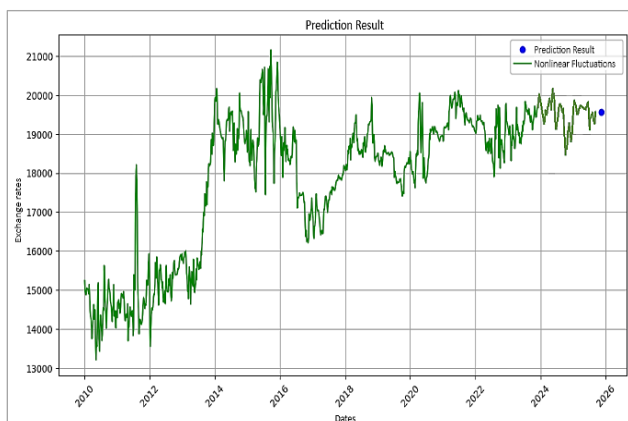


Gambar 10. Fold 5

Pada Gambar 10 *fold 5*, model menunjukkan performa yang baik dan tidak ada indikasi *overfitting* atau *underfitting* yang signifikan. Baik *loss training* maupun *loss validasi* menurun secara stabil seiring bertambahnya *epoch* pelatihan. *Loss validasi* mencapai nilai yang rendah dan cenderung datar di akhir iterasi, yang merupakan tanda positif bahwa model telah mempelajari pola data dengan baik.

Gap antara *loss training* dan *loss validasi* tidak terlalu besar, menunjukkan model dapat menggeneralisasi dengan baik pada data validasi yang belum pernah dilihat sebelumnya. Hasil pada *fold 5* ini sangat memuaskan dan mengindikasikan bahwa model memiliki kapasitas yang cukup untuk mempelajari kompleksitas data, serta tidak terlalu *overfitting* atau *underfitting*.

Setelah pelatihan dan evaluasi menggunakan *k-fold cross-validation*, model diuji pada data uji yang tidak terlihat. Pengguna juga dapat memberikan tanggal di masa depan untuk memprediksi nilai tukar GBP/IDR. Proses prediksi melibatkan penggunaan model untuk menghasilkan nilai tukar yang diharapkan di masa depan. Berbagai grafik seperti grafik prediksi pada tanggal tertentu, grafik aktual vs prediksi, dan grafik metrik validasi silang ditampilkan untuk memberikan pemahaman visual tentang kinerja model. Grafik hasil peramalan dapat dilihat pada Gambar 11.



Gambar 11. Hasil Peramalan

Gambar 11 menampilkan grafik hasil prediksi nilai tukar mata uang. Sumbu x mewakili tahun, sedangkan sumbu y menunjukkan nilai yang diprediksi. Fluktuasi pada grafik garis mengindikasikan bahwa variabel yang diprediksi telah mengalami perubahan selama periode yang ditampilkan. Pendekatan ini memberikan dasar yang kuat untuk memprediksi nilai tukar dengan memanfaatkan sejumlah besar data historis dan fitur eksogen yang relevan serta melakukan evaluasi yang cermat menggunakan teknik *k-fold cross validation*.

IV. KESIMPULAN

Penelitian ini menggunakan model NARX-NN yang terdiri dari dua lapisan LSTM dan satu lapisan *dense* untuk memprediksi nilai tukar GBP/IDR. Pemanfaatan data historis dan variabel eksogen yang relevan, membuat pendekatan ini berpotensi memberikan pemahaman yang lebih mendalam mengenai fluktuasi nilai tukar mata uang. Hasil evaluasi dengan menggunakan metode *k-fold cross-validation* menunjukkan bahwa pembagian data pelatihan 80/20 menghasilkan prediksi yang akurat, dengan tingkat kesalahan yang rendah dan nilai *R-squared* yang mendekati 1. Hal ini menunjukkan kemampuan model untuk menjelaskan variasi data dengan baik. Selain itu, penambahan variabel ekonomi seperti inflasi dan jumlah uang beredar sebagai faktor eksogen tambahan dalam model dapat meningkatkan kemampuan model untuk memprediksi nilai tukar mata uang dengan lebih akurat, karena faktor-faktor ini memiliki pengaruh yang signifikan terhadap fluktuasi nilai tukar.

V. SARAN

Saran untuk penelitian selanjutnya adalah mengeksplorasi variabel eksogen tambahan untuk memperkaya model, seperti faktor ekonomi makro atau kebijakan moneter. Pengembangan model lebih lanjut dapat ditingkatkan dengan mengeksplorasi arsitektur jaringan yang lebih kompleks atau teknik pembelajaran mendalam yang lebih baru. Menguji model pada dataset lain dapat membantu memvalidasi generalisasi model yang dikembangkan. Selain itu, analisis faktor eksternal yang mempengaruhi nilai tukar, seperti peristiwa geopolitik atau kebijakan pemerintah, juga dapat memberikan pengaruh tambahan dalam proses peramalan nilai tukar mata uang. Penelitian ini memberikan dasar yang kuat untuk pengembangan peramalan nilai tukar yang lebih akurat dan dapat diandalkan dengan menggunakan teknologi jaringan syaraf tiruan. Implikasi dari penelitian ini tidak hanya relevan dalam konteks nilai tukar GBP/IDR, tetapi juga dapat diterapkan secara lebih luas dalam pemodelan dan peramalan fluktuasi pasar keuangan.

DAFTAR PUSTAKA

- [1] P. Indonesia, *Undang - Undang Republik Indonesia Nomor 7 Tahun 2011 Tentang Mata Uang*. Jakarta, 2011.
- [2] D. N. Setiawan, "Prediksi Nilai Tukar Rupiah Terhadap Dolar Amerika Dengan Menggunakan Algoritme Genetika - Backpropagation," *Repository Universitas Brawijaya*, Apr. 2018.
- [3] P. Indonesia, "Peraturan Bank Indonesia Nomor 24/7PBI/2022 Tentang Transaksi Dipasar Valuta Asing," *Lembaran Negara Republik Indonesia*, Jul. 2022, [Online]. Available: www.peraturan.go.id
- [4] A. Chatarine, L. P. Wiagustini, L. Gede, and S. Artini, "Pengaruh Risiko Kredit dan Risiko Nilai Tukar Terhadap Profitabilitas dan Return Saham Perbankan di BEI," *E-Jurnal Ekonomi dan Bisnis Universitas Udayana*, vol. 5, no. 11, 2016.
- [5] I. S. Suseno, "Sistem dan Kebijakan Nilai Tukar," Jakarta, May 2004.
- [6] K. Mawardi, "Dampak Nilai Tukar Mata Uang Terhadap Perdagangan Internasional," *Ocean Engineering : Jurnal Ilmu Teknik dan Teknologi Maritim*, vol. 2, no. 1, pp. 88–102, 2023, doi: 10.58192/ocean.v2i2.959.
- [7] H. Hoang Gia BAO and H. LE Phong, "The Prominence of USD/CNY in China-EU and China-UK Trade," *Journal of Asian Finance*, vol. 8, no. 11, pp. 47–0066, 2021, doi: 10.13106/jafeb.2021.vol8.no11.0047.
- [8] M. Markova, "Foreign exchange rate forecasting by artificial neural networks," in *AIP Conference Proceedings*, American Institute of Physics Inc., Oct. 2019. doi: 10.1063/1.5130812.
- [9] V. K. Irawati, "Pengaruh Guncangan Suku Bunga The Fed Terhadap Indikator Makroprudensial Indonesia," *Studi Ekonomi Pembangunan*, 2023.
- [10] W. Khamidah and R. Sugiharti, "Faktor yang Mempengaruhi Nilai Tukar Rupiah terhadap Dollar Amerika, Euro dan Poundsterling," *Universitas Tidar*, vol. 5, pp. 40–52, Apr. 2022.
- [11] D. Murjiani and R. Mochamad Adiyanto, "Pengaruh Inflasi, Suku Bunga, Dan Nilai Tukar Terhadap Nilai Perusahaan Pada Perusahaan Sub Sektor Makanan Dan Minuman Yang Terdaftar Di Bursa Efek Indonesia (Bei) Periode 2017-2022," *Accounting and Management Journal*, vol. 7, no. 1, Jul. 2023.
- [12] R. Maronrong and K. Nugrhoho, "Pengaruh Inflasi, Suku Bunga Dan Nilai Tukar Terhadap Harga Saham Studi Kasus Pada Perusahaan Manufaktur Otomotif Terdaftar Di Bursa Efek Indonesia Tahun 2012 – 2017," *Jurnal STEI Ekonomi*, vol. 26, no. 02, Dec. 2017.
- [13] R. Br Silitonga *et al.*, "Pengaruh ekspor, impor, dan inflasi terhadap nilai tukar rupiah di Indonesia," 2017. [Online]. Available: <https://ejournal.unsri.ac.id/index.php/jep/index>
- [14] I. P. Masitha *et al.*, "Pengaruh Suku Bunga, Nilai Tukar Rupiah, Inflasi, Ekspor Dan Impor Terhadap Cadangan Devisa Di Indonesia," *Universitas Asahan*, 2018.
- [15] F. Hamdi, H. Budiantoro, R. Sani, R. Rusydi, and S. Defit, "Penerapan Metode Neural Network untuk Prediksi Harga Bawang Putih di Kota Singkawang," *Jurnal Vocational Teknik Elektronika dan Informatika*, vol. 12, no. 2, 2024, [Online]. Available: <http://ejournal.unp.ac.id/index.php/voteknika/>
- [16] M. Markova, "Forecasting EUR/USD exchange rate with nonlinear autoregressive with exogenous input neural networks," in *AIP Conference Proceedings*, American Institute of Physics Inc., Apr. 2022. doi: 10.1063/5.0083532.
- [17] C. L. Cocianu and M.-S. Avramescu, "New Approaches of NARX-Based Forecasting Model. A Case Study on CHF-RON Exchange Rate," *Informatika Economica*, vol. 22, no. 2/2018, pp. 5–13, Jun. 2018, doi: 10.12948/issn14531305/22.2.2018.01.
- [18] T. Damrongsakmethee and V.-E. Neagoe, "A Neural NARX Approach for Exchange Rate Forecasting," Jun. 2019.
- [19] R. Arisanti and M. D. Puspita, "Non-Linear Autoregressive Neural Network With Exogenous Variable In Forecasting USD/IDR Exchange Rate," *Communications in Mathematical Biology and Neuroscience*, vol. 2022, 2022, doi: 10.28919/cmbn/6931.
- [20] D. Yulia Hidayah, "Peramalan Nilai Tukar Rupiah terhadap Dollar Amerika dengan Metode Fuzzy Time Series (FTS) Markov Chain," *UNNES Journal of Mathematics*, vol. 10, no. 2, pp. 85–95, 2021, [Online]. Available: <http://journal.unnes.ac.id/sju/index.php/ujm>
- [21] Z. Darvas and Z. Schepp, "Exchange rates and fundamentals: Forecasting with long maturity forward rates," *J Int Money Finance*, vol. 143, May 2024, doi: 10.1016/j.jimonfin.2024.103067.
- [22] P. Liu, Z. Wang, D. Liu, J. Wang, and T. Wang, "A CNN-STLSTM-AM model for forecasting USD/RMB exchange rate," *Journal of Engineering Research (Kuwait)*, vol. 11, no. 2, Jun. 2023, doi: 10.1016/j.jer.2023.100079.
- [23] N. A. Firman, "Model Peramalan Kurs Referensi Dolar Terhadap Rupiah Menggunakan Metode Jaringan Syaraf Tiruan Dengan Propogasi Balik," *Universitas Hasanudin Makassar*, Sep. 2020.

- [24] A. A. Romdhoni and E. Suryani, "Peramalan Nilai Tukar Mata Uang Dollar AS terhadap Rupiah Menggunakan Neural Network Ensemble Bagging," *JURNALITSMART*, vol. 2, no. 2, 2013.
- [25] G. Benrhmach, K. Namir, A. Namir, and J. Bouyaghroumni, "Nonlinear Autoregressive Neural Network and Extended Kalman Filters for Prediction of Financial Time Series," *J Appl Math*, vol. 2020, 2020, doi: 10.1155/2020/5057801.
- [26] D. R. Febrianti, M. A. Tiro, and S. Sudarmin, "Metode Vector Autoregressive (VAR) dalam Menganalisis Pengaruh Kurs Mata Uang Terhadap Ekspor Dan Impor Di Indonesia," *VARIANSI: Journal of Statistics and Its application on Teaching and Research*, vol. 3, no. 1, p. 23, Mar. 2021, doi: 10.35580/variansiunm14645.
- [27] M. Melina, H. Napitupulu, A. Sambas, A. Murniati, and V. Adimurti Kusumaningtyas, "Artificial Neural Network-Based Machine Learning Approach to Stock Market Prediction Model on the Indonesia Stock Exchange During the COVID-19," *Engineering Letters*, vol. 30, no. 3, Sep. 2022, [Online]. Available: <https://www.researchgate.net/publication/362983602>
- [28] J. E. Simarmata, "Application of Expectation Maximization Algorithm in Estimating Parameter Values of Maximum Likelihood Model," *Journal of Research in Mathematics Trends and Technology*, vol. 3, no. 1, pp. 34–39, Mar. 2021, doi: 10.32734/jormtt.v3i1.8331.
- [29] V. Kotu and B. Deshpande, "Time Series Forecasting," in *Data Science*, Elsevier, 2019, pp. 395–445. doi: 10.1016/B978-0-12-814761-0.00012-5.
- [30] Admin, "Regression Model Accuracy (MAE, MSE, RMSE, R-squared) Check in R," DataTechNotes. Accessed: Nov. 15, 2023. [Online]. Available: <https://www.datatechnotes.com/2019/02/regression-model-accuracy-mae-mse-rmse.html>