

Prediksi Nilai Tukar Mata Uang Menggunakan Algoritma Long Short-Term Memory dan Random Forest

Imam Hidayat*, Lalu A. Syamsul Irfan Akbar, Ahmad Sjamsjiar Rachman

Fakultas Teknik, Program Studi Teknik Elektro, Universitas Mataram, Mataram, Indonesia

Email: ^{1,*}imamhd3@gmail.com, ²irfan@unram.ac.id, ³asrachman@unram.ac.id

Email Penulis Korespondensi: imamhd3@gmail.com

Submitted: 05/11/2024; Accepted: 15/11/2024; Published: 15/11/2024

Abstrak—Nilai tukar mata uang adalah pertukaran antar dua mata uang yang berbeda, yaitu merupakan perbandingan nilai atau harga antara kedua mata uang tersebut dan perbandingan inilah sering disebut dengan kurs. Pergerakan nilai tukar mata uang sangat kompleks dan dipengaruhi oleh banyak faktor antara lain faktor ekonomi, politik, dan sosial. Dalam upaya untuk memahami dan memprediksi pergerakan ini, banyak penelitian telah dilakukan menggunakan berbagai metode analisis dan prediksi, akan tetapi belum ada kesepakatan metode yang terbaik untuk memprediksi pergerakan nilai tukar mata uang. Penelitian ini bertujuan untuk melakukan perbandingan performa antara algoritma *Long Short Term-Memory* dan *Random Forest* dalam memprediksi nilai tukar mata uang Rupiah (IDR) terhadap Dolar Singapura (SGD). Dengan memanfaatkan data historis pergerakan nilai tukar mata uang data utama dan data nilai ekspor impor dari kedua negara sebagai variabel tambahan, Setelah melalui serangkaian tahapan mulai dari pengumpulan data, *preprocessing*, hingga pemodelan, hasil evaluasi menunjukkan bahwa algoritma *Long Short Term-Memory* memiliki performa lebih baik dengan *Root Mean Square Error* (RMSE) sebesar 152.28, *Mean Absolute Percentage Error* (MAPE) 1.25%, dan akurasi 98.74%, sedangkan *Random Forest* memiliki RMSE 284.3, MAPE 2.07%, dan akurasi 97.93%. Hasil ini menunjukkan bahwa *Long Short Term-Memory* lebih unggul dalam menangkap pola perubahan nilai tukar yang kompleks, menjadikannya pilihan yang lebih efektif dalam memprediksi nilai tukar mata uang dibandingkan *Random Forest*.

Kata Kunci: Prediksi Nilai Tukar; Long Short-Term Memory; Random Forest; Machine Learning; SGD-IDR, Ekspor-Impor

Abstract—Currency exchange rate is an exchange between two different currencies, which is a comparison of the value or price between the two currencies and this comparison is often called the exchange rate. Currency exchange rate movements are very complex and influenced by many factors, including economic, political, and social factors. In an effort to understand and predict these movements, many studies have been conducted using various methods of analysis and prediction. However, there is still no consensus on the best method to predict exchange rate movements. This study aims to compare the performance between the Long Short Term-Memory and Random Forest algorithms in predicting the exchange rate of the Rupiah (IDR) against the Singapore Dollar (SGD). By utilizing the historical data of currency exchange rate movements, the main data and the data of import and export values from the two countries as additional variables. After going through a series of stages ranging from data collection, preprocessing, to modeling, the evaluation results show that the Long Short Term-Memory algorithm has a better performance with a Root Mean Square Error (RMSE) of 152.28, Mean Absolute Percentage Error (MAPE) 1.25%, and 98.74% accuracy, while Random Forest has an RMSE of 284.3, a MAPE of 2.07%, and an accuracy of 97.93%. These results show that Long Short Term-Memory is superior in capturing complex exchange rate change patterns, making it a more effective choice in predicting currency exchange rates than Random Forest.

Keywords: Exchange Rate Prediction; Long Short-Term Memory; Random Forest; Machine Learning; SGD-IDR; Export-Import

1. PENDAHULUAN

Pasar mata uang atau pasar valuta asing adalah pasar global dimana mata uang dari berbagai negara diperdagangkan. Pergerakan nilai tukar mata uang sangat kompleks dan dipengaruhi oleh banyak faktor antara lain faktor ekonomi, politik, dan sosial. Dalam upaya untuk memahami dan memprediksi pergerakan ini, banyak penelitian telah dilakukan menggunakan berbagai metode analisis dan prediksi[1]. Nilai tukar adalah pertukaran antara dua mata uang yang berbeda, yaitu merupakan perbandingan nilai atau harga antara kedua mata uang tersebut dan perbandingan inilah sering disebut dengan kurs. Dalam kurs terdapat istilah kurs jual, kurs beli, dan kurs tengah. Istilah tersebut digunakan oleh bank/perusahaan *money changer* untuk memperoleh keuntungan dari jasa penukaran mata uang asing. Arus modal antar negara sangat memengaruhi nilai mata uang setiap negara. Dibidang investasi, kurs Rupiah juga dapat menjadi salah satu faktor yang mampu mempengaruhi indeks harga saham[2]. Sebagai langkahantisipasi maka perlu dilakukan prediksi terhadap kurs Rupiah terhadap mata uang asing.

Machine learning merupakan suatu ilmu yang membuat sistem dapat secara otomatis belajar sendiri tanpa harus berulang kali diprogram oleh manusia. *Machine Learning* sendiri merupakan salah satu disiplin ilmu dalam kecerdasan buatan atau yang biasa dikenal dengan *Artificial Intelligent*[3]. Dalam implementasinya, *machine learning* memiliki banyak metode yang dapat digunakan untuk menangani klasifikasi, *clustering*, dan pengelolaan data lainnya. Dalam penelitian, digunakan beberapa model machine learning yang diantaranya terdapat algoritma LSTM (*Long Short Term-Memory*) dan *Random Forest*[4]. Kelebihan dari algoritma LSTM dapat mengatasi dependensi jangka panjang, memiliki akurasi yang tinggi[5], dan juga LSTM sangat fleksibel dalam paramterisasi, LSTM dapat diatur dengan berbagai parameter seperti jumlah *layer*, *neuron* per *layer*, dan *epoch*, sehingga dapat disesuaikan dengan kebutuhan aplikasi[6]. Sedangkan kelebihan algoritma *Random*

Forest dapat mengatasi *overfitting*, lebih stabil, dan toleransi terhadap data yang tidak seimbang[7]. Banyak penelitian sebelumnya telah menunjukkan bahwa algoritma-algoritma *machine learning* efektif dalam meramalkan pergerakan nilai tukar mata uang, namun belum ada kesepakatan yang jelas tentang algoritma terbaik untuk digunakan.

Penelitian yang dilakukan oleh Sianturi dkk. membahas tentang penggunaan algoritma LSTM untuk memprediksi harga ethereum, dimana pada penelitian ini menggunakan 1509 baris sampel data dari periode januari 2018 sampai januari 2022 dengan parameter data yang digunakan adalah *date*, *price*, *open*, *high*, *low*, dan *volume*. Pada penelitian ini menunjukkan bahwa hasil MSE (*Mean Squared Error*) terbaik dihasilkan dari proporsi data *training* dan data *testing* sebesar 70% : 30%, dengan rata-rata nilai MSE sebesar 0,018[8]. Penelitian yang dilakukan oleh Karno membahas tentang analisis data *time series*, yang dimana pada penelitian ini menggunakan algoritma LSTM dan ARIMA (*Autocorrelation Integreted Moving Average*) dalam bahasa *python* untuk memprediksi saham Telkom. Hasil dari studi ini menggunakan 7 kombinasi proses transformasi dapat meningkatkan tingkat akurasi prediksi dari ARIMA dan LSTM. Dimana akurasi *machine learning* LSTM dengan menggunakan data saham Telkom memiliki akurasi yang lebih tinggi dibandingkan dengan ARIMA[9]. Penelitian yang dilakukan oleh Bhandari dkk. ini membahas tentang penggunaan algoritma LSTM untuk prediksi *stock market*, dimana pada penelitian ini menggunakan algoritma LSTM untuk memprediksi nilai *adj close* hari berikutnya dari index S&P 500. Dalam penelitian ini menggunakan model LSTM *singelayer* dan model LSTM *multilayer* dengan variabel input yang sudah ditentukan, dan kinerja dari kedua model dibandingkan dengan evaluasi matrik RMSE (*Root Mean Square Error*), MAPE (*Mean Absolute Percentage Error*), dan koefisien korelasi (R). Hasil evaluasi menunjukan bahwa model LSTM *single layer* memiliki performa dan akurasi yang lebih baik dibandingkan model LSTM *Multilayer*[10].

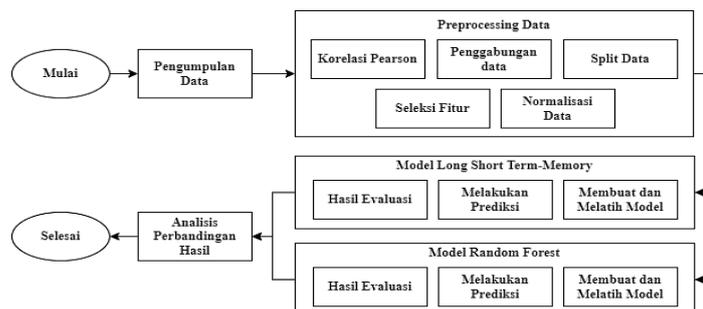
Penelitian yang dilakukan oleh Tsuji membahas tentang penggunaan algoritma *Random Forest* untuk memprediksi nilai tukar mata uang. Dalam penelitian ini dilakukan empat nilai tukar mata uang, yaitu Dollar Kanada, Dollar Australia, Pound Inggris, dan Euro terhadap dolar AS. Penelitian ini mengungkapkan bahwa hasil prediksi dari algoritma *Random Forest* menunjukkan akurasi prediksi yang tinggi. Nilai R-squared menunjukkan prediksi untuk keempat mata uang sangat tinggi, dengan nilai R-squared tertinggi adalah EUR/USD sebesar 0,987[11]. Penelitian yang dilakukan oleh Chen dkk. ini membahas tentang penggunaan *machine learning* untuk memprediksi nilai tukar mata uang Yen Jepang terhadap Dollar Amerika, dimana pada penelitian ini menggunakan algoritma *Random Forest* dan SVM (*Support Vector Machine*) untuk memprediksi nilai tukar mata uang Yen Jepang terhadap Dollar Amerika. Dalam penelitian ini terdapat dua *output* akurasi yaitu dari *input* data asli dan dari *input* data yang diencode, *output* dari *input* data yang diencode menunjukan akurasi yang lebih tinggi 5-10%. Selain itu, penelitian ini menunjukkan bahwa *Random Forest* cukup baik dalam menangani kasus ini, sedangkan SVM memiliki kesulitan dalam menangani *input* berdimensi tinggi[12].

Berdasarkan referensi dari lima penelitian sebelumnya, pada penelitian ini bertujuan untuk melakukan perbandingan performa antara algoritma LSTM dan *Random Forest* dalam memprediksi nilai tukar mata uang Rupiah (IDR) terhadap Dolar Singapura (SGD). Dengan memanfaatkan data historis pergerakan nilai tukar mata uang dan data nilai ekspor impor dari kedua negara sebagai variabel tambahan, penelitian ini akan menyelidiki dan membandingkan kemampuan dari LSTM dan *Random Forest* dalam mengenali pola-pola perubahan nilai tukar yang kompleks serta memprediksi perubahan nilai tukar. Hasil dari penelitian ini diharapkan dapat memberikan wawasan yang berharga bagi praktisi keuangan dan peneliti dalam memilih algoritma yang sesuai untuk meramalkan pergerakan nilai tukar mata uang secara efektif.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan yang dirancang secara sistematis untuk menghasilkan prediksi nilai tukar mata uang Rupiah (IDR) terhadap Dolar Singapura (SGD) dengan menggunakan dua model prediksi, yaitu LSTM (*Long Short-Term Memory*) dan *Random Forest*. Adapun alur penelitian ini dapat dilihat pada gambar 1.



Gambar 1. Diagram Alur Penelitian

Penelitian ini dilakukan dengan mengikuti beberapa tahapan sebagaimana terlihat pada gambar 1 diagram alur penelitian. Tahapan pertama dimulai dengan pengumpulan data, data yang akan digunakan pada penelitian ini ada dua yaitu data nilai tukar mata uang IDR terhadap SGD dan data nilai ekspor impor antara Indonesia dengan Singapura sebagai variabel tambahan, data nilai ekspor impor ini diharapkan dapat memberikan informasi tambahan yang dapat meningkatkan performa model prediksi. Adapun data nilai tukar mata uang SGD-IDR yang digunakan pada penelitian ini didapatkan dari platform *yahoofinance*[13], sedangkan data nilai ekspor impor didapatkan dari website resmi Badan Pusat Statistik Indonesia[14]. Seperti yang terlihat pada tabel 1 dan tabel 2.

Tabel 1. Data Nilai Tukar Mata Uang SGD-IDR

Date	Open	High	Low	Close	Adj Close
31/01/2014	9.565	9.594	9.379	9.566	9.566
28/02/2014	9.231	9.157	9.222	9.231	9.231
31/03/2014	8.851	8.981	8.822	8.849	8.849
30/04/2014	9.183	9.183	9.041	9.183	9.183
30/05/2014	9.268	9.268	9.133	9.269	9.269
30/06/2014	9.607	9.611	9.354	9.607	9.607
31/07/2014	9.285	9.286	9.139	9.287	9.287
29/08/2014	9.221	9.252	9.221	9.221	9.221
30/09/2014	9.403	9.655	9.389	9.404	9.404
30/10/2014	9.379	9.432	9.321	9.380	9.380
...
28/06/2024	12.058	12.079	12.031	12.057	12.057

Pada tabel 1 merupakan data nilai tukar SGD-IDR yang digunakan pada penelitian ini. Pada data terdapat beberapa kolom yang berperan penting sebagai fitur yang akan digunakan pada penelitian yaitu kolom *Open*, *High*, *Low*, *Close*, dan *Adj Close*. Data nilai tukar mata uang SGD-IDR yang digunakan pada penelitian ini adalah data dari tahun 2014 sampai 2024.

Tabel 2. Data Nilai Ekspor Impor

Tahun	Bulan	Ekspor	Impor
2014	JANUARI	1.601.220.876,00	2.178.755.987,00
	FEBRUARI	1.321.135.392,00	1.950.829.535,00
	MARET	1.418.706.917,00	2.192.797.166,00
	APRIL	1.428.200.650,00	2.454.277.774,00
	MEI	1.414.064.589,00	1.928.610.098,00
	JUNI	1.477.384.054,00	2.018.892.839,00
	JULI	1.451.382.849,00	2.149.347.293,00
	AGUSTUS	1.272.945.220,00	1.930.919.451,00
	SEPTEMBER	1.450.419.745,00	2.156.906.448,00
	OKTOBER	1.402.587.349,00	2.415.173.347,00
	NOVEMBER	1.165.267.461,00	1.962.298.368,00
	DESEMBER	1.325.010.708,00	1.847.002.410,00
...
2014	JUNI	909.195.552,94	2.062.809.532,00

Pada tabel 2 merupakan data nilai ekspor impor yang digunakan pada penelitian ini. Data ekspor dan impor digunakan sebagai variabel pendukung dalam model prediksi karena keduanya dapat mempengaruhi nilai tukar mata uang suatu negara. Sama seperti data nilai tukar mata uang SGD-IDR, data nilai ekspor impor yang digunakan pada penelitian ini adalah data dari tahun 2014 sampai 2024.

Tahapan selanjutnya adalah *preprocessing* data, tahapan ini melibatkan serangkaian proses yang bertujuan untuk membersihkan, mengubah, dan menyiapkan data agar siap digunakan dalam pemodelan[15]. Berikut adalah beberapa proses yang dilakukan dalam tahapan *preprocessing* data. Proses pertama adalah korelasi *pearson*, proses ini bertujuan untuk mengukur hubungan antara data nilai tukar mata uang SGD-IDR dengan data nilai ekspor impor[16]. Setelah dilakukan korelasi *pearson*, proses selanjutnya adalah menggabungkan data nilai tukar mata uang SGD-IDR dengan data nilai ekspor impor menjadi satu dataset, penggabungan ini bertujuan untuk membuat dataset yang komprehensif, dimana kedua data tersebut bisa saling mendukung dalam proses analisis dan prediksi. Proses selanjutnya adalah *split* data, pada proses ini dilakukan pembagian data menjadi dua bagian yaitu data latih dan data uji, data latih digunakan untuk melatih model, sedangkan data uji digunakan untuk memvalidasi hasil prediksi model[17]. Selanjutnya proses seleksi fitur, seleksi fitur adalah proses memilih subset fitur tertentu dari dataset yang akan digunakan sebagai input untuk model prediksi[18]. Proses terakhir pada tahapan *preprocessing* data adalah proses normalisasi data, seluruh fitur

dalam data dinormalisasi menggunakan metode *Min-Max Scaling* agar data berada dalam rentang 0 hingga 1, hal ini dilakukan untuk meningkatkan kinerja model yang akan digunakan[19].

Tahapan Selanjutnya adalah model dan evaluasi, pada tahap ini dilakukan pemodelan prediksi data menggunakan algoritma LSTM dan *Random Forest*. LSTM merupakan salah satu arsitektur dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi masalah pada RNN, seperti kesulitan dalam menangani urutan data yang panjang, ledakan gradien (*exploding gradient*), dan hilangnya gradien (*vanishing gradient*) saat memproses data yang tersimpan dalam memori jangka panjang. Oleh karena itu, LSTM sangat cocok digunakan untuk kasus prediksi dan klasifikasi yang melibatkan data terkait waktu[5]. Sedangkan *Random Forest* adalah metode yang menggunakan banyak pohon keputusan untuk meningkatkan akurasi. Setiap pohon dibangun dari subset acak data dan fitur, sehingga model dapat berkerja dengan baik untuk mengatasi *overfitting*. Prediksi akhir diperoleh dari rata-rata atau *voting* hasil semua pohon, membuatnya efektif untuk menangani data non-linear dan kompleks. *Random Forest* sangat cocok untuk regresi dan klasifikasi, serta mampu menangani dataset besar dengan berbagai jenis variabel[20]. Masing-masing model akan dilatih dengan menggunakan data latih yang telah disiapkan pada tahap sebelumnya. Setelah pelatihan model, selanjutnya masing-masing model melakukan prediksi terhadap data uji untuk mendapatkan hasil prediksi. Sedangkan evaluasi model dilakukan untuk mengetahui kinerja model. Evaluasi model dilakukan dengan menggunakan beberapa matrik performa, antara lain seperti RMSE (*Root Mean Square Error*), MAPE (*Mean Absolute Percentage Error*), dan akurasi. RMSE digunakan untuk menghitung akar kuadrat dari rata-rata kesalahan kuadrat antara nilai prediksi dan nilai aktual[21], rumus untuk menghitung nilai RMSE dapat dilihat pada persamaan (1). MAPE digunakan untuk menghitung kesalahan prediksi dalam bentuk persentase[22], rumus untuk menghitung nilai MAPE dapat dilihat pada persamaan (2). Akurasi dihitung sebagai selisih antara 100% dan MAPE, rumus untuk menghitung nilai akurasi dapat dilihat pada persamaan (3).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - A_i)^2} \tag{1}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - p_i}{A_i} \right| \times 100\% \tag{2}$$

$$Akurasi = 100\% - MAPE \tag{3}$$

Tahapan terakhir pada penelitian ini adalah analisis perbandingan hasil, pada tahap ini dilakukan analisis perbandingan antara hasil prediksi yang diperoleh dari dua model yang digunakan, yaitu model LSTM dan *Random Forest*. Analisis ini bertujuan untuk mengidentifikasi kelebihan dan kekurangan masing-masing model dalam memprediksi nilai tukar mata uang SGD-IDR. Berdasarkan hasil evaluasi, dilakukan perbandingan beberapa metrik performa, seperti RMSE, MAPE, dan tingkat akurasi.

3. HASIL DAN PEMBAHASAN

Pada bagian ini membahas tentang hasil dari tahap *preprocessing data*, model dan evaluasi, hingga tahap analisis perbandingan hasil dari algoritma LSTM (*Long Short Term-Memory*) dan *Random Forest* dengan menggunakan *tools* pada aplikasi *Visual Studio Code* dengan bahasa pemrograman *Python*.

3.1 Preprocessing Data

Pada tahapan *preprocessing data*, data nilai tukar SGD-IDR serta data nilai ekspor dan impor antara Indonesia dan Singapura diolah untuk mempersiapkan dataset yang siap digunakan untuk pemodelan. Adapun proses yang pertama dilakukan pada tahap ini adalah melihat korelasi *pearson* antara variabel *Adj Close* nilai tukar SGD-IDR dengan nilai ekspor-impor. Berdasarkan proses yang sudah dilakukan, nilai korelasi antara SGD-IDR dan ekspor impor menunjukkan bahwa terdapat korelasi negatif, yaitu dengan nilai -0.26 untuk ekspor dan -0.04 untuk impor. Setelah korelasi *pearson*, data nilai tukar SGD-IDR digabungkan dengan data nilai ekspor impor menjadi satu. Penggabungan ini menghasilkan dataset yang komprehensif, di mana setiap entri dalam dataset memiliki nilai tukar, nilai ekspor, dan nilai impor untuk masing-masing periode waktu.

Tabel 3. Hasil Penggabungan Data

Date	Open	High	Low	Close	Adj Close	Ekspor	Impor
31/01/2014	9.565	9.594	9.379	9.566	9.566	1.601.220.876,00	2.178.755.987,00
28/02/2014	9.231	9.157	9.222	9.231	9.231	1.321.135.392,00	1.950.829.535,00
31/03/2014	8.851	8.981	8.822	8.849	8.849	1.418.706.917,00	2.192.797.166,00
30/04/2014	9.183	9.183	9.041	9.183	9.183	1.428.200.650,00	2.454.277.774,00
30/05/2014	9.268	9.268	9.133	9.269	9.269	1.414.064.589,00	1.928.610.098,00
...
28/06/2024	12.058	12.079	12.031	12.057	12.057	909.195.552,94	2.062.809.532,00

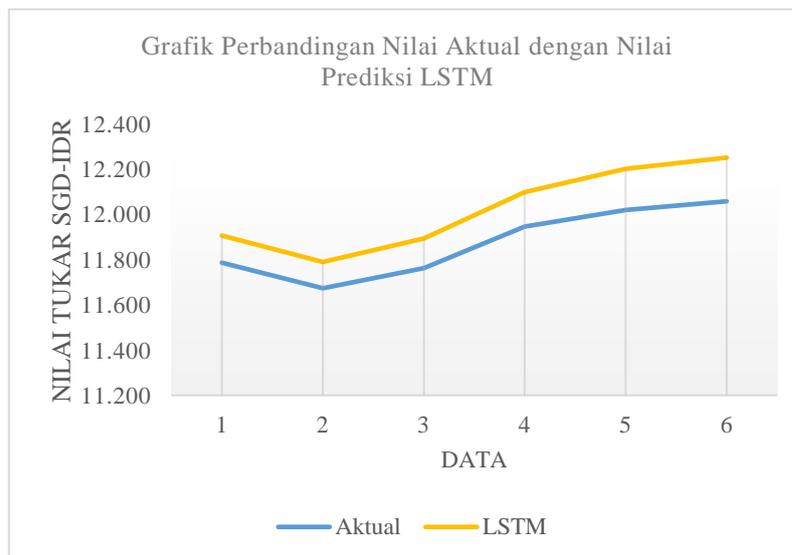
Proses selanjutnya adalah proses *split* data, pembagian data yang telah dilakukan pada penelitian ini menggunakan metode pembagian berdasarkan tahun, dengan pembagian data dari 2023 kebawah sebagai data latih dan data tahun 2024 sebagai data uji. Setelah melalui proses *split* data, selanjutnya dilakukan seleksi fitur pada data. Seleksi fitur bertujuan untuk memilih fitur-fitur yang paling relevan dalam proses prediksi. Fitur yang digunakan dalam model antara lain *Open*, *High*, *Low*, *Close*, *Adj Close*, *Ekspor*, dan *Impor*. Adapun proses terakhir yang dilakukan pada tahap *preprocessing* data adalah proses normalisasi data. Pada proses normalisasi data, metode yang digunakan adalah metode *Min-Max Scaler* yang dapat merubah data numerik kedalam rentang yang spesifik (0-1), proses normalisasi ini membanting mengatasi perbedaan skala antara fitur-fitur yang ada dalam dataset, sehingga semua fitur yang berada pada dataset akan memiliki rentang nilai yang sama antara 0 hingga 1.

3.2 Model dan Evaluasi

Pada tahap ini dilakukan pemodelan prediksi menggunakan algoritma LSTM dan *Random Forest*, setiap model diuji dengan dataset yang telah dipersiapkan dan hasil evaluasi dari setiap model dibandingkan untuk menentukan model dengan performa terbaik.

3.1.1 LSTM (*Long Short Term-Memory*)

Model LSTM dibangun dengan arsitektur sekuensial, yang memungkinkan penambahan lapisan secara bertahap. Lapisan pertama yang ditambahkan adalah LSTM dengan 50 unit memori, yang dirancang untuk memproses data sekuensial dengan *input* dari data latih. Pada lapisan ini, digunakan parameter *return_sequences=True* agar seluruh urutan *output* dari LSTM dapat diteruskan ke lapisan berikutnya. Selanjutnya, lapisan LSTM kedua ditambahkan dengan 50 unit memori, namun kali ini hanya menghasilkan *output* terakhir, karena setelahnya model akan dihubungkan ke lapisan *Dense*. Lapisan *Dense* ini memiliki 1 neuron yang berfungsi sebagai *output* untuk menghasilkan satu nilai prediksi tunggal, sesuai dengan target regresi. Model kemudian dikompilasi menggunakan fungsi *loss mean squared error*, yang cocok untuk mengukur selisih kuadrat antara nilai prediksi dan aktual dalam regresi, serta *optimizer adam*, yang dipilih karena efisiensinya dalam mengkonvergensi model lebih cepat. Setelah itu, model dilatih menggunakan data pelatihan selama 40 *epoch* dengan *batch size* sebesar 16. Proses pelatihan dilakukan secara iteratif dan ditampilkan secara detail melalui parameter *verbose=1*, sehingga perkembangan *loss* pada setiap *epoch* dapat dipantau. Setelah model dilatih, prediksi dilakukan pada data uji untuk mendapatkan nilai prediksi SGD-IDR menggunakan LSTM. Selanjutnya dilakukan evaluasi untuk mengetahui kinerja model, evaluasi model dilakukan dengan cara melihat parameter seperti RMSE, MAPE, dan akurasi dari hasil prediksi yang sudah dilakukan. Hasil evaluasi menunjukkan bahwa model LSTM memiliki RMSE sebesar 152.28, MAPE sebesar 1.25, dan akurasi sebesar 98.74%.



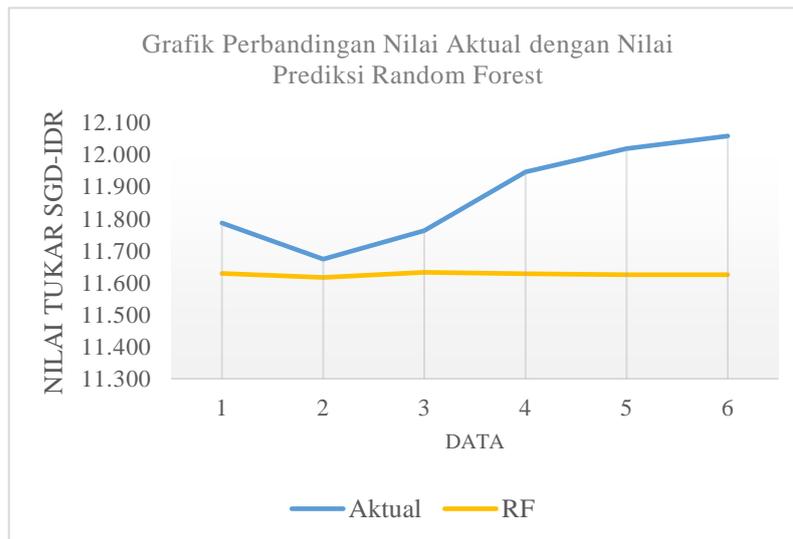
Gambar 2. Grafik Perbandingan Nilai Aktual dengan Nilai Prediksi LSTM

Berdasarkan grafik pada gambar 2, terlihat bahwa model berhasil menangkap tren umum kenaikan nilai tukar dari titik data ke-2 hingga titik data ke-5, meskipun terdapat selisih yang cukup konsisten antara hasil prediksi dan nilai aktual. Garis biru yang mewakili nilai aktual berada di bawah garis kuning yang menunjukkan nilai prediksi LSTM, mengindikasikan adanya kecenderungan model untuk *overpredict* nilai tukar SGD-IDR. Perbedaan ini semakin jelas di titik data akhir, di mana nilai aktual berada cukup jauh di bawah nilai prediksi LSTM, meskipun keduanya tetap menunjukkan pola kenaikan yang serupa. Berdasarkan hasil evaluasi model, RMSE tercatat sebesar 152.28, yang mengindikasikan bahwa terdapat deviasi atau kesalahan prediksi yang cukup kecil. Selain itu, nilai MAPE sebesar 1.25% menunjukkan bahwa rata-rata kesalahan relatif prediksi

terhadap data aktual sangat kecil. Akurasi model LSTM ini tercatat sangat tinggi, yaitu sebesar 98.74%, yang mengindikasikan bahwa model dapat memprediksi nilai tukar dengan tingkat ketepatan yang sangat baik.

3.1.2 Random Forest

Model *Random Forest* dibangun menggunakan *library Scikit-learn* untuk melakukan regresi. Pada implementasi ini, *Random Forest* dipilih dengan 100 pohon keputusan ($n_estimators=100$) sebagai parameter utama. Setiap pohon dalam *Random Forest* berperan untuk melakukan prediksi secara independen, dan hasil akhir diperoleh dari rata-rata prediksi semua pohon, yang dapat meningkatkan akurasi dan mengurangi *overfitting*. Model diinisialisasi dengan parameter *random state=42* untuk memastikan bahwa hasil pelatihan dapat direproduksi dengan nilai awal yang sama. Data latih harus diubah menjadi dua dimensi karena *Random Forest* membutuhkan *input* dalam bentuk tabular, bukan sekuensial seperti yang digunakan pada model LSTM. Oleh karena itu, dilakukan *reshape* dari bentuk (*samples, timesteps, features*) menjadi (*samples, features*). Sementara itu, target *ytrain* diubah menjadi satu dimensi menggunakan *ytrain.ravel()*, agar sesuai dengan format yang diperlukan untuk regresi. Setelah itu, model dilatih dengan memanggil metode *fit()*, yang mengoptimalkan pohon keputusan berdasarkan data input dan target untuk menghasilkan prediksi yang optimal. Model ini bersifat non-sekuensial, sehingga tidak membutuhkan proses propagasi urutan seperti LSTM, namun tetap memberikan hasil prediksi yang kuat dalam tugas regresi. Setelah model dilatih, prediksi dilakukan pada data uji untuk mendapatkan nilai prediksi SGD-IDR menggunakan *Random Forest*. Selanjutnya dilakukan evaluasi untuk mengetahui kinerja model, evaluasi model dilakukan dengan cara melihat parameter seperti RMSE, MAPE, dan akurasi dari hasil prediksi yang sudah dilakukan. Hasil evaluasi menunjukkan bahwa model *Random Forest* memiliki RMSE sebesar 284.3, MAPE sebesar 2.07, dan akurasi sebesar 97.93%.

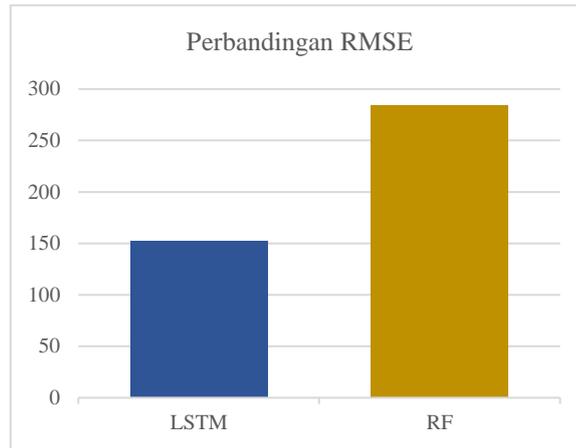


Gambar 3. Grafik Perbandingan Nilai Aktual dengan Nilai Prediksi *Random Forest*

Berdasarkan grafik pada gambar 3, yang membandingkan nilai aktual dan nilai prediksi menggunakan model *Random Forest*, terlihat bahwa terdapat perbedaan yang signifikan antara prediksi model dengan nilai aktual. Garis biru, yang merepresentasikan nilai aktual, menunjukkan tren yang cukup fluktuatif dengan kenaikan yang tajam mulai dari titik data ke-2 hingga ke-5. Sebaliknya, garis kuning yang menunjukkan nilai prediksi dari model *Random Forest* terlihat cenderung datar, menunjukkan bahwa model tidak sepenuhnya menangkap pola pergerakan yang terjadi pada nilai aktual. Berdasarkan evaluasi model, didapatkan nilai RMSE sebesar 284.30, yang menunjukkan adanya deviasi cukup besar antara prediksi model dengan nilai aktual. Selain itu, nilai MAPE sebesar 2.07% menandakan bahwa kesalahan relatif model cukup rendah, sementara akurasi sebesar 97.93% menunjukkan bahwa model ini memiliki performa yang baik dalam memprediksi nilai SGD-IDR secara keseluruhan, meskipun tidak mampu menangkap tren volatilitas jangka pendek secara akurat.

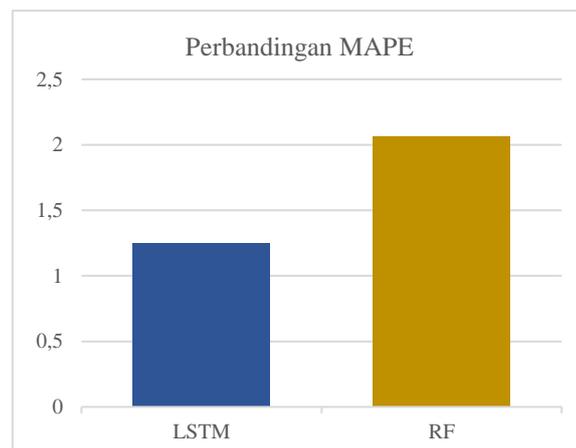
3.2 Analisis Perbandingan Hasil

Pada tahap ini, dilakukan analisis perbandingan antara hasil prediksi yang diperoleh dari dua model yang digunakan, yaitu LSTM dan *Random Forest*. Analisis ini bertujuan untuk mengidentifikasi kelebihan dan kekurangan masing-masing model dalam memprediksi nilai tukar mata uang SGD-IDR. Berdasarkan hasil evaluasi, dilakukan perbandingan beberapa metrik performa, seperti RMSE, MAPE, dan tingkat akurasi.



Gambar 4. Grafik perbandingan RMSE

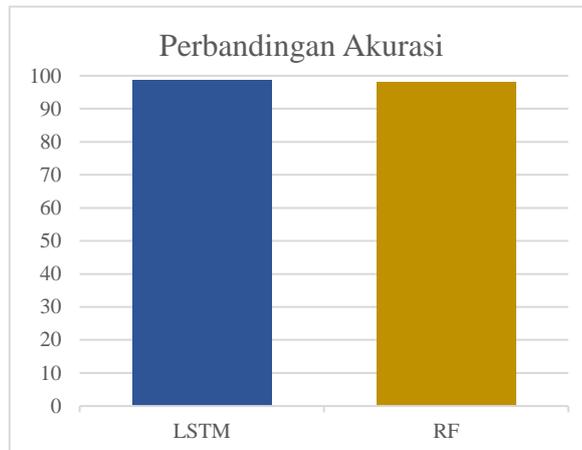
Berdasarkan grafik pada gambar 4 dapat dianalisa bahwa nilai RMSE model LSTM lebih rendah dibandingkan model *Random Forest*. Model LSTM menghasilkan nilai RMSE sebesar 152.28, yang menunjukkan bahwa kesalahan prediksi antara nilai aktual dan prediksi berada dalam kisaran yang relatif kecil. RMSE, sebagai metrik yang sensitif terhadap outlier dan kesalahan besar, memberikan gambaran bahwa model LSTM mampu menangkap pola dalam data dengan baik dan menjaga deviasi prediksi tetap rendah. Artinya, meskipun ada beberapa perbedaan antara nilai aktual dan prediksi, selisih tersebut tidak signifikan dan lebih konsisten. Hal ini menandakan bahwa LSTM memiliki kemampuan yang baik dalam memahami pola waktu dan tren yang ada dalam data nilai tukar SGD-IDR. Di sisi lain, model *Random Forest* memiliki nilai RMSE yang jauh lebih tinggi dari model LSTM, yaitu sebesar 284.30. Nilai RMSE yang tinggi ini mengindikasikan bahwa model *Random Forest* mengalami lebih banyak kesulitan dalam memprediksi nilai tukar SGD-IDR secara akurat. Model *Random Forest* cenderung menghasilkan deviasi yang lebih besar antara nilai aktual dan prediksi, terutama ketika dihadapkan pada fluktuasi yang lebih tajam dalam data. Hal ini menunjukkan bahwa *Random Forest* kurang mampu menangkap pola yang kompleks dalam data dengan baik, sehingga kesalahan prediksinya menjadi lebih besar. Berdasarkan perbandingan nilai RMSE ini, dapat disimpulkan bahwa model LSTM menunjukkan performa yang lebih baik dibandingkan dengan *Random Forest* dalam hal prediksi nilai tukar SGD-IDR. LSTM lebih efektif dalam menjaga tingkat kesalahan prediksi tetap rendah, menunjukkan bahwa model ini lebih handal untuk menangani data yang memiliki pola fluktuasi temporal yang kompleks.



Gambar 5. Grafik perbandingan MAPE

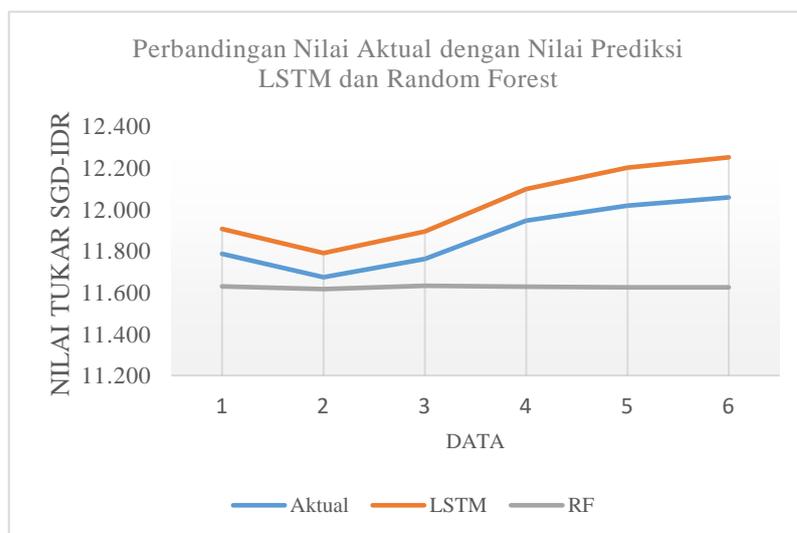
Berdasarkan grafik pada gambar 5 dapat dianalisa bahwa model LSTM memiliki nilai MAPE yang lebih rendah dibandingkan model *Random Forest*. Model LSTM menghasilkan nilai MAPE sebesar 1.2552%, yang mengindikasikan bahwa rata-rata kesalahan prediksi model ini hanya sekitar 1.25% dari nilai aktual. MAPE adalah metrik yang mengukur seberapa besar deviasi prediksi terhadap nilai aktual dalam bentuk persentase, sehingga semakin rendah nilai MAPE, semakin baik performa model. Nilai MAPE yang rendah pada LSTM menunjukkan bahwa model ini memiliki tingkat akurasi yang tinggi dalam memprediksi nilai tukar SGD-IDR, dengan kesalahan yang sangat kecil dan konsisten terhadap nilai aktual. Sedangkan model *Random Forest* menghasilkan nilai MAPE yang lebih tinggi, yaitu sebesar 2.0681%. Ini berarti rata-rata kesalahan prediksi model ini adalah sekitar 2.06% dari nilai aktual. Walaupun nilai MAPE *Random Forest* tidak terlalu besar, namun perbedaannya dengan LSTM menunjukkan bahwa model *Random Forest* memiliki tingkat deviasi yang lebih besar terhadap nilai aktual. Dengan kata lain, *Random Forest* cenderung memiliki lebih banyak

ketidakakuratan dalam prediksi, terutama pada data dengan pola yang lebih kompleks dan fluktuasi yang tajam. Berdasarkan perbandingan nilai MAPE ini, dapat disimpulkan bahwa model LSTM menunjukkan performa yang lebih baik dibandingkan *Random Forest* dalam prediksi nilai tukar SGD-IDR. LSTM mampu menangkap pola temporal dengan lebih efisien.



Gambar 6. Grafik perbandingan akurasi

Berdasarkan grafik pada gambar 6 dapat dianalisa bahwa model LSTM memiliki akurasi yang lebih tinggi dibandingkan model *Random Forest*. Model LSTM mencapai akurasi sebesar 98.75%, yang menunjukkan bahwa prediksi nilai tukar SGD-IDR oleh LSTM sangat dekat dengan nilai aktualnya. Akurasi yang tinggi ini mencerminkan bahwa model LSTM mampu mengenali pola-pola fluktuasi dan tren dalam data dengan baik, sehingga sebagian besar prediksi yang dihasilkan mendekati nilai aktual. Akurasi yang diperoleh oleh menunjukkan tingkat keandalan model yang sangat baik dalam menangani data dengan pola temporal yang kompleks. Sedangkan model *Random Forest* memiliki akurasi yang sedikit lebih rendah, yaitu sebesar 97.93%. Meskipun nilai ini juga tergolong tinggi, namun perbedaannya dengan akurasi LSTM menunjukkan bahwa *Random Forest* sedikit kurang mampu menangkap pola data yang lebih dinamis dan fluktuatif. Meskipun prediksi yang dihasilkan oleh *Random Forest* masih tergolong baik, ada lebih banyak kesalahan kecil yang terjadi dibandingkan dengan model LSTM, terutama ketika dihadapkan pada fluktuasi yang lebih tajam dalam data. Berdasarkan perbandingan akurasi ini memperkuat kesimpulan bahwa model LSTM lebih unggul dalam hal prediksi nilai tukar SGD-IDR dibandingkan dengan *Random Forest*. LSTM tidak hanya memiliki tingkat kesalahan prediksi yang lebih rendah, tetapi juga mampu menjaga akurasi prediksi mendekati sempurna. Dengan akurasi yang lebih tinggi.



Gambar 7. Grafik perbandingan nilai aktual dengan nilai prediksi

Berdasarkan grafik pada gambar 7 dapat dianalisa bahwa model LSTM dapat mengikuti tren data dari nilai aktual dengan cukup baik, meskipun terdapat selisih yang cukup konsisten antara nilai prediksi LSTM dengan nilai aktual, model LSTM tetap dapat menangkap pola fluktuatif dari nilai aktual. Sedangkan model *Random Forest* menunjukkan perbedaan yang signifikan antara nilai prediksi *Random Forest* dengan nilai aktual, model *Random Forest* kurang mampu menangkap pola fluktuatif dari nilai aktual, sehingga nilai prediksi *Random Forest* cenderung datar.

Secara keseluruhan, model LSTM terbukti lebih unggul dibandingkan *Random Forest* dalam memprediksi nilai tukar SGD-IDR, baik dari segi RMSE, MAPE, akurasi, maupun kemampuan menangkap pola temporal yang kompleks. LSTM lebih handal dan konsisten dalam menghadapi data dengan fluktuasi tajam, menjadikannya pilihan yang lebih baik untuk prediksi nilai tukar SGD-IDR.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan dan mengacu pada tujuan dalam penelitian ini, dapat disimpulkan bahwa algoritma LSTM menunjukkan performa yang lebih baik dibandingkan dengan algoritma *Random Forest* dalam memprediksi nilai tukar SGD-IDR. Hal ini terlihat dari hasil evaluasi model LSTM dan *Random Forest*, di mana model LSTM menghasilkan RMSE sebesar 152.28, MAPE sebesar 1.25, dan akurasi sebesar 98.75%. Sementara itu, model *Random Forest* menghasilkan RMSE sebesar 284.3, MAPE sebesar 2.068, dan akurasi sebesar 97.93%. Algoritma LSTM lebih unggul dalam mengidentifikasi pola perubahan nilai tukar yang kompleks dibandingkan *Random Forest*. Hasil analisis menunjukkan bahwa LSTM mampu menangkap pola fluktuasi dengan baik, menghasilkan prediksi yang lebih konsisten mendekati nilai aktual. Sementara itu, *Random Forest* cenderung kesulitan dalam memprediksi data dengan fluktuasi tajam, mengakibatkan kesalahan prediksi yang lebih besar dan deviasi yang lebih tinggi. Dari hasil ini, LSTM terbukti lebih efektif dibandingkan *Random Forest* dalam konteks memprediksi nilai tukar SGD-IDR. Tingkat kesalahan yang lebih rendah, akurasi yang lebih tinggi, dan kemampuan menangkap pola temporal yang kompleks menunjukkan bahwa LSTM merupakan pilihan yang lebih tepat untuk digunakan dalam prediksi nilai tukar mata uang. Pengujian pada data lain sangat disarankan untuk menguji kedua model ini pada data mata uang lain atau jenis data time series lainnya untuk memvalidasi kehandalan hasil penelitian ini dan mengetahui sejauh mana keunggulan LSTM berlaku pada prediksi dengan konteks berbeda.

REFERENCES

- [1] N. A. Zahwa, R. Tri, T. Panggabean, K. A. Matondang, and R. Indriani, "PASAR VALUTA ASING DAN SISTEM NILAI TUKAR," 2023, [Available] <http://jasmien.cattleyadf.org/index.php/jas/article/view/157>.
- [2] G. P. B. Are, S. H. Sitorus, J. Prof, H. Hadari, and N. Pontianak, "PREDIKSI NILAI TUKAR MATA UANG RUPIAH TERHADAP DOLAR AMERIKA MENGGUNAKAN METODE HIDDEN MARKOV MODEL," *Coding: Jurnal Komputer dan Aplikasi*, vol. 08, no. 01, pp. 44–54, 2020, doi: <https://doi.org/10.26418/coding.v8i1.39192>.
- [3] K. Kristiawan and A. Widjaja, "Perbandingan Algoritma Machine Learning dalam Menilai Sebuah Lokasi Toko Ritel," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 1, Apr. 2021, doi: 10.28932/jutisi.v7i1.3182.
- [4] N. Nurul Hakim, "Implementasi Machine Learning pada Sistem Prediksi Kejadian dan Lokasi Patah Rel Kereta Api di Indonesia," *Sistem Cerdas*, vol. 03, 2020, doi: <https://doi.org/10.37396/jsc.v3i1.58>.
- [5] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, Aug. 2023, doi: 10.23960/jitet.v11i3.3250.
- [6] G. Budiprasetyo, M. Hani'ah, and D. Z. Aflah, "Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM)," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 3, pp. 164–172, Jan. 2023, doi: 10.25077/teknosi.v8i3.2022.164-172.
- [7] Feby Dita, "Serba Serbi Machine Learning Model Random Forest," Access Date 20 Sept 2024, DQLab.
- [8] T. B. Sianturi, I. Cholissodin, and N. Yudistira, "Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 7, no. 3, pp. 1101–1107, 2023, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [9] A. Satyo and B. Karno, "Analisis Data Time Series Menggunakan LSTM (Long Short Term Memory) dan ARIMA (Autocorrelation Integrated Moving Average) dalam Bahasa Python," *ULTIMA InfoSys*, vol. XI, no. 1, 2020.
- [10] H. N. Bhandari, B. Rimal, N. R. Pokhrel, R. Rimal, K. R. Dahal, and R. K. C. Khatri, "Predicting stock market index using LSTM," *Machine Learning with Applications*, vol. 9, p. 100320, Sep. 2022, doi: 10.1016/j.mlwa.2022.100320.
- [11] C. Tsuji, "Exchange Rate Forecasting via a Machine Learning Approach," *iBusiness*, vol. 14, no. 03, pp. 119–126, 2022, doi: 10.4236/ib.2022.143009.
- [12] R. C. Chen, Y. C. Shiao, C. Dewi, and Q. E. Liu, "Predicting the Japanese Yen to US Dollar Exchange Rate Based on Machine Learning Models," *International Computer Symposium*, pp. 141–146, Dec. 2020, doi: 10.1109/ICS51289.2020.00037.
- [13] Yahoo Finance, "SGD/IDR Singapore Dollar to Indonesian Rupiah Exchange Rate," Access Date 20 Sept 2024, Yahoo Finance.
- [14] Badan Pusat Statistik, "Ekspor Impor Indonesia," Access Date 20 Sept 2024, BPS - Statistics Indonesia.

- [15] N. Putu, S. Wati, and C. Pramatha, "Penerapan Long Short Term Memory dalam Mengklasifikasi Jenis Ujaran Kebencian pada Tweet Bahasa Indonesia," 2022.
- [16] A. Setiawan, "Korelasi Pearson: Panduan Lengkap dalam Analisis Data Statistika," 2011, Smartstat.
- [17] W. Willy, D. P. Rini, and S. Samsuryadi, "Perbandingan Algoritma Random Forest Classifier, Support Vector Machine dan Logistic Regression Clasifier Pada Masalah High Dimension (Studi Kasus: Klasifikasi Fake News)," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 5, no. 4, p. 1720, Oct. 2021, doi: 10.30865/mib.v5i4.3177.
- [18] I. Behravan and S. M. Razavi, "Stock Price Prediction Using Machine Learning and Swarm Intelligence," *Journal of Electrical and Computer Engineering Innovations*, vol. 8, no. 1, pp. 31–40, 2020, doi: 10.22061/JECEI.2020.6898.346.
- [19] N. Aini, M. Arif, I. T. Agustin, and Z. B. Toyibah, "Implementasi Algoritma Random Forest untuk Klasifikasi Bidang MSIB di Prodi Pendidikan Informatika," *Jurnal Informatika*, vol. 11, no. 1, pp. 11–16, Apr. 2024, doi: 10.31294/inf.v11i1.20637.
- [20] Suci Amaliah, M. Nusrang, and A. Aswi, "Penerapan Metode Random Forest Untuk Klasifikasi Varian Minuman Kopi di Kedai Kopi Konijiwa Bantaeng," *Journal of Statistics and Its application on Teaching and Research*, vol. 4, no. 3, pp. 121–127, Dec. 2022, doi: 10.35580/variasiunm31.
- [21] M. Aditya Pratama, M. Munawaroh, W. Joko Pranoto, P. Studi Teknik Informatika, F. Sains dan Teknologi, and U. Muhammadiyah Kalimantan Timur, "Perbandingan Performa Algoritma Linear Regresi dan Random Forest untuk Prediksi Harga Bawang Merah di Kota Samarinda," *Jurnal Ilmu Teknik*, vol. 1, no. 2, pp. 172–182, 2024, doi: 10.62017/tekonik.
- [22] A. M. Sabarina, H. C. Rustamaji, and H. Himawan, "Prediction Of Drug Sales Using Methods Forecasting Double Exponential Smoothing (Case Study : Hospital Pharmacy of Condong Catur)," *Jurnal Informatika dan Teknologi Informasi*, vol. 18, no. 1, pp. 106–117, 2021, doi: 10.31515/telematika.v18i1.4586.