

PERBANDINGAN PROPHET, XGBOOST, MLP UNTUK PREDIKSI KURS USD KE IDR

Khansa Maritza Ar-Rahmah¹⁾ Raffi Cahya Tria Putra Yasin²⁾

^{1) 2)} Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara
Jl. Letjen S. Parman No.1, Jakarta 11440 Indonesia
email : khansa.535220241@stu.untar.ac.id¹⁾, email : raffi.535220224@stu.untar.ac.id²⁾

ABSTRAK

Peramalan kurs USD/IDR yang akurat sangat krusial bagi stabilitas ekonomi Indonesia. Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja tiga model machine learning, yaitu Prophet, XGBoost, dan Multi-Layer Perceptron (MLP) dalam memprediksi kurs tengah harian USD/IDR. Metode penelitian yang digunakan adalah analisis kuantitatif komparatif pada data historis JISDOR dari Oktober 2019 hingga Oktober 2025. Model Prophet diterapkan sebagai pendekatan time series murni, sedangkan XGBoost dan MLP diuji menggunakan transformasi supervised learning dengan rekayasa fitur (fitur lag, rolling statistics, dan kalender). Kinerja model dievaluasi menggunakan metrik MAE dan RMSE pada dua skema pembagian data (80:20 dan 70:30). Hasil penelitian menunjukkan bahwa XGBoost secara signifikan mengungguli model lainnya, terutama pada skema 80:20, dengan mencapai MAE terendah (Rp100,60), MAPE (0,62%), dan R^2 positif (0,8603). Sebaliknya, Prophet dan MLP dengan konfigurasi dasar gagal menangkap volatilitas data dan menghasilkan R^2 negatif. Temuan ini mengindikasikan bahwa pendekatan supervised learning dengan rekayasa fitur, khususnya menggunakan XGBoost, lebih efektif untuk memprediksi kurs USD/IDR jangka pendek.

Key words

JISDOR, Multi-Layer Perceptron (MLP), Peramalan Nilai Tukar, Prophet, XGBoost,

1. Pendahuluan

Nilai tukar Rupiah terhadap Dolar Amerika Serikat (USD/IDR) merupakan salah satu indikator makroekonomi terpenting bagi Indonesia. Fluktuasinya berdampak langsung terhadap perdagangan internasional, laju inflasi, arus investasi, hingga beban utang luar negeri [1]. Oleh karena itu, kemampuan untuk memprediksi pergerakan kurs USD/IDR secara akurat menjadi krusial bagi para pelaku bisnis dalam mengambil keputusan strategis dan bagi Bank Indonesia dalam merumuskan kebijakan moneter yang efektif. Namun, sifat kurs USD/IDR yang sangat dinamis dan fluktuatif,

dipengaruhi oleh multifaktor yang kompleks baik dari sisi global maupun domestik, menjadikan peramalan nilai tukar sebagai tantangan yang signifikan dalam bidang ekonomi dan *data science*. Dampak akibat dari kebijakan ini, baik dalam sektor moneter maupun sektor riil, sangat signifikan terhadap perkembangan perekonomian nasional. Salah satu contohnya yaitu terdepresiasi nilai tukar Rupiah terhadap USD yang mengakibatkan aktivitas bisnis serta ekonomi mengalami ketidakpastian dalam pengambilan keputusan [2].

Berbagai penelitian terdahulu telah mengeksplorasi penggunaan model statistik dan *machine learning* untuk peramalan nilai tukar dan harga komoditas keuangan. Misalnya, penelitian berjudul “Prediksi Harga Saham Top 10 NASDAQ dengan Time Series Prophet” menunjukkan bahwa model Prophet memiliki tingkat akurasi yang baik dengan nilai rata-rata MAPE sebesar 1,23%, di mana hasil prediksi mampu mengikuti pola harga saham Microsoft secara konsisten [3]. Prophet juga terbukti efektif dalam menangkap pola musiman mingguan pada data saham NASDAQ, seperti kecenderungan kenaikan harga pada hari Rabu dan penurunan pada Kamis dan Jumat.

Selain itu, penelitian lain berjudul “Konfigurasi Model Prophet Untuk Prediksi Harga Saham Sektor Teknologi di Indonesia yang Akurat” menegaskan bahwa performa Prophet meningkat secara signifikan ketika menggunakan dataset yang lebih besar dan melalui proses *hyperparameter tuning* [4]. Hasil penelitian tersebut menunjukkan nilai MAPE sebesar 15%, yang mengindikasikan tingkat kesalahan relatif rendah dan kemampuan Prophet dalam menyesuaikan diri terhadap dinamika data keuangan di Indonesia.

Lebih lanjut, penelitian pada “Proceedings of the 2022 International Conference on Bigdata Blockchain and Economy Management (ICBBEM 2022)” menerapkan algoritma XGBoost untuk peramalan harga saham berfrekuensi tinggi [5]. Hasilnya menunjukkan bahwa model ini mampu mencapai akurasi tinggi, menangkap tren pergerakan harga dengan baik, serta membuktikan efektivitas XGBoost sebagai pendekatan ilmiah dalam analisis ekonomi dan manajemen modern.

Dari sisi model berbasis *neural network*, penelitian “Algoritme Machine Learning Multi-Layer Perceptron dan Recurrent Neural Network untuk Prediksi Harga Cabai Merah Besar di Kota Tangerang” membandingkan

performa MLP dan RNN dalam peramalan harga komoditas [6]. Hasil penelitian tersebut menunjukkan bahwa model MLP dengan *optimizer* rmsprop memberikan hasil yang lebih baik dibandingkan RNN, dengan nilai MAPE sebesar 3,79%, menandakan kemampuan MLP dalam menangkap pola non-linear pada data harga pangan. Di sisi lain, pendekatan berbasis ensemble learning juga menunjukkan hasil menjanjikan. Penelitian “Pemodelan Prediktif Konsumsi Energi Listrik di Pabrik Baja Berbasis XGBoost untuk Pengelolaan Sumber Daya Berkelanjutan” mengimplementasikan model XGBoost Regressor untuk memprediksi konsumsi energi listrik dengan hasil akurasi tinggi (MAE 0,41 kWh, RMSE 0,81 kWh, R^2 0,9993). Hasil ini menegaskan efektivitas XGBoost dalam menangkap hubungan kompleks antarvariabel dan mendukung efisiensi energi industri.

Sementara itu, pendekatan berbasis *hybrid model* juga mulai berkembang, seperti pada penelitian “Time Series Forecasting-Based Kubernetes Autoscaling Using Facebook Prophet and Long Short-Term Memory”, yang mengombinasikan Prophet dan LSTM untuk prediksi beban kerja aplikasi *cloud computing* [7]. Hasilnya menunjukkan peningkatan akurasi prediksi hingga 65-90% dibandingkan model tunggal, membuktikan efektivitas integrasi Prophet dengan model *deep learning* untuk pola data yang kompleks dan musiman.

Temuan-temuan tersebut memperlihatkan bahwa Prophet dan MLP memiliki potensi besar dalam menangani data deret waktu (*time series*) dengan karakteristik musiman dan fluktuatif, baik pada sektor keuangan maupun non-keuangan. Namun demikian, kinerja model sangat bergantung pada karakteristik data, pemilihan fitur, serta proses *tuning* parameter, sehingga diperlukan penelitian lebih lanjut untuk mengetahui model yang paling sesuai dalam konteks peramalan kurs USD/IDR di Indonesia.

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja tiga model peramalan populer dalam memprediksi kurs tengah harian USD/IDR berdasarkan data historis Jakarta Interbank Spot Dollar Rate (JISDOR). Secara khusus, penelitian ini mengimplementasikan tiga model peramalan, yaitu Prophet, XGBoost, dan Multi-Layer Perceptron (MLP), untuk memprediksi pergerakan nilai tukar. Selain itu, penelitian ini juga mengukur serta membandingkan tingkat akurasi ketiga model menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE) pada dua skema pembagian data, yaitu 80% data latih dan 20% data uji serta 70% data latih dan 30% data uji. Lebih lanjut, penelitian ini menganalisis pendekatan pemodelan yang memberikan hasil paling optimal untuk karakteristik data kurs harian, baik menggunakan model spesialis *time series* (Prophet) maupun model *supervised learning* dengan *feature engineering* (XGBoost dan MLP). Metode penelitian yang digunakan adalah analisis kuantitatif komparatif. Tiga model peramalan, yaitu Prophet, XGBoost Regressor, dan MLP Regressor, diterapkan pada data historis harian kurs tengah USD/IDR

(JISDOR) yang dipublikasikan oleh Bank Indonesia dari Oktober 2019 hingga Oktober 2025. Model Prophet diaplikasikan langsung pada data *time series* asli, sedangkan model XGBoost dan MLP memanfaatkan transformasi data menjadi format *supervised learning* melalui *feature engineering* yang mencakup fitur lag (nilai kurs sebelumnya pada H-1, H-3, H-7, H-14, H-30), *rolling statistics* (rata-rata dan standar deviasi 7 hari), serta fitur berbasis kalender (bulan, hari dalam seminggu, dll). Kinerja model dievaluasi menggunakan metrik MAE dan RMSE pada dua skenario pembagian data, yaitu 80% data latih dan 20% data uji, serta 70% data latih dan 30% data uji, dengan tetap menjaga urutan waktu data.


Kontribusi utama dari penelitian ini terletak pada analisis komparatif tiga pendekatan pemodelan yang berbeda secara fundamental, yaitu model *time series* spesialis (Prophet), model *ensemble tree* (XGBoost), dan model *neural network* dasar (MLP), dalam konteks peramalan kurs harian USD/IDR yang volatil. Penelitian ini memberikan bukti nyata mengenai efektivitas transformasi masalah *time series* menjadi *supervised learning* melalui *feature engineering* dibandingkan pendekatan holistik. Selain itu, penelitian ini menyajikan perbandingan langsung antara XGBoost dan MLP menggunakan set fitur yang identik, serta menganalisis dampak rasio pembagian data latih dan data uji terhadap akurasi prediksi. Hasil penelitian diharapkan dapat memberikan rekomendasi praktis bagi para praktisi dan pembuat kebijakan dalam memilih metode *forecasting* nilai tukar yang lebih andal.

2. Metode Penelitian

2.1. Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan. Tahap pertama yaitu pengumpulan dataset historis kurs tengah harian Dolar AS (USD) terhadap Rupiah (IDR). Data mentah tersebut kemudian diolah ke dalam format deret waktu (*time series*). Selanjutnya, dilakukan tahap pra-pemrosesan data yang mencakup pembersihan, transformasi tipe data, dan pengurutan kronologis untuk memastikan kesiapan data sebelum proses pemodelan.

Tahap berikutnya adalah implementasi prediksi menggunakan tiga model *machine learning*, yaitu Prophet, XGBoost, dan MLP Regressor. Setelah itu, kinerja masing-masing model dievaluasi menggunakan metrik kuantitatif. Terakhir, dilakukan analisis komparatif untuk membandingkan efektivitas dan akurasi ketiga model tersebut dalam memprediksi kurs. Diagram alir yang mengilustrasikan tahapan penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Tahapan penelitian yang dilakukan

2.2. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari sumber data publik resmi Bank Indonesia, yaitu melalui layanan Jakarta Interbank Spot Dollar Rate (JISDOR).

Dataset mencakup data historis harian kurs tengah Dolar Amerika Serikat (USD) terhadap Rupiah (IDR) pada rentang waktu 1 Oktober 2019 hingga 1 Oktober 2025. Dataset ini terdiri atas 1451 sampel data, dengan variabel utama meliputi tanggal pencatatan dan nilai kurs. Contoh sampel data yang digunakan dapat dilihat pada Tabel 1.

Tabel 1 Dataset Kurs Tengah Harian USD/IDR (JISDOR)

No	Tanggal	Kurs
1	10/1/2025 12:00:00 AM	16680
2	9/30/2025 12:00:00 AM	16692
3	9/29/2025 12:00:00 AM	16680
4	9/26/2025 12:00:00 AM	16775
...	...	...
1451	10/1/2019 12:00:00 AM	14196

2.3. Pra-pemrosesan Data

Tahap pra-pemrosesan data bertujuan untuk membersihkan dan menyiapkan dataset historis kurs tengah harian USD/IDR (JISDOR) agar sesuai untuk analisis dan pemodelan deret waktu. Selanjutnya, dilakukan beberapa langkah pembersihan dan penyesuaian data sebagai berikut:

1. Menghapus kolom nomor urut yang tidak relevan.
2. Mengganti nama kolom menjadi ds (untuk tanggal) dan y (untuk kurs), sesuai format standar yang dibutuhkan oleh model Prophet.
3. Mengonversi kolom ds dari tipe data string menjadi tipe data datetime dan memastikan interpretasi format tanggal yang benar.
4. Mengurutkan data secara kronologis dari tanggal terlama ke tanggal terbaru, yang merupakan langkah penting untuk analisis time series.

2.4. Feature Engineering

Model XGBoost dan MLP Regressor beroperasi dalam pendekatan *supervised learning*. Namun, sebagian besar algoritma *machine learning* tidak dapat diterapkan secara langsung pada data deret waktu. Cara populer untuk mengatasi masalah ini adalah dengan mengubah deret waktu menjadi representasi vektor fitur, kemudian menerapkan model prediktif tradisional pada representasi baru ini [8]. Sejalan dengan pendekatan tersebut, diperlukan transformasi data deret waktu menjadi format fitur prediktor (X) dan variabel target (y). Oleh karena itu, dilakukan tahap rekayasa fitur untuk mengekstrak informasi relevan dari data kurs (y) dan tanggal (ds). Fitur-fitur yang dibuat dikategorikan sebagai berikut:

1. **Fitur Lag (Nilai Lampau):** Meliputi nilai kurs pada hari-hari sebelumnya, yaitu y_{lag_1} (H-1), y_{lag_3} (H-3), y_{lag_7} (H-7), y_{lag_14} (H-14), dan y_{lag_30} (H-30). Pembuatan fitur lag bertujuan untuk menangkap dependensi temporal (ketergantungan nilai saat ini terhadap nilai sebelumnya) dalam data kurs pada rentang waktu pendek hingga menengah.
2. **Fitur Rolling Statistics (Statistik Bergulir):** Meliputi $rolling_mean_7$ (rata-rata nilai kurs selama 7 hari terakhir) dan $rolling_std_7$ (standar deviasi nilai kurs selama 7 hari terakhir). Perhitungan fitur ini menggunakan metode `.shift(1)` untuk mencegah kebocoran data (*data leakage*), memastikan bahwa statistik dihitung hanya berdasarkan data masa lalu. Fitur ini dirancang untuk menangkap tren lokal dan tingkat volatilitas data dalam jendela waktu tertentu.
3. **Fitur Kalender (Fitur Waktu):** Terdiri dari informasi waktu yang diekstrak langsung dari variabel ds, yaitu month (bulan), day_of_week (hari dalam seminggu, misal Senin=0, Minggu=6), day_of_month (tanggal dalam bulan), week_of_year (minggu dalam setahun), dan year (tahun). Fitur kalender bertujuan untuk membantu model mengenali potensi pola musiman atau siklus yang terkait dengan kalender.

Proses rekayasa fitur ini menghasilkan total 12 variabel prediktor (X). Sebagai konsekuensi dari penggunaan fitur lag dengan jeda terjauh (y_{lag_30}) dan fitur rolling yang memerlukan data historis minimal 7 hari, beberapa observasi awal dalam dataset akan memiliki nilai *Not a Number* (NaN). Oleh karena itu, dilakukan penghapusan baris data yang mengandung nilai NaN. Sehingga, dataset final untuk model *supervised* terdiri dari 1407 observasi yang valid.

2.5. Pemisahan Data Latih dan Data Uji

Pemisahan data menjadi data latih (*training set*) dan data uji (*test set*) adalah tahap penting dalam *machine*

learning. Pembagian yang tepat krusial untuk menilai kemampuan generalisasi model dan mencegah *overfitting*, memastikan model bekerja baik pada data baru [9].

Pembagian pada penelitian ini dilakukan menggunakan metode pemisahan berbasis waktu (*temporal split*). Metode ini memastikan bahwa data latih selalu terdiri dari observasi yang lebih awal secara kronologis dibandingkan data uji, sehingga menjaga integritas urutan waktu dan mensimulasikan skenario peramalan di dunia nyata.

Dua skenario rasio pembagian data diterapkan dalam penelitian ini. Skenario pembagian data pertama menggunakan rasio 80% untuk data latih dan 20% untuk data uji (80:20). Pada skema ini, 80% observasi terawal dari dataset dialokasikan sebagai data latih, yang berjumlah 1160 observasi untuk dataset asli (yang akan digunakan oleh Prophet) dan 1125 observasi untuk dataset yang telah melalui rekayasa fitur (yang akan digunakan oleh XGBoost dan MLP). Sisa 20% observasi terakhir, yang berjumlah 291 observasi untuk dataset asli dan 282 observasi untuk dataset berfitur, dialokasikan sebagai data uji.

Skenario pembagian data kedua menerapkan rasio 70% untuk data latih dan 30% untuk data uji (70:30). Dalam skema ini, 70% observasi terawal dari dataset digunakan sebagai data latih, setara dengan 1015 observasi pada dataset asli dan 984 observasi pada dataset berfitur. Sementara itu, 30% observasi terakhir, yang mencakup 436 observasi pada dataset asli dan 423 observasi pada dataset berfitur digunakan sebagai data uji.

2.6. Prophet

Prophet adalah sebuah prosedur peramalan data deret waktu yang dikembangkan oleh tim Core Data Science Facebook. Tujuan utamanya adalah memungkinkan peramalan dalam skala besar (*at scale*), yang artinya Prophet dirancang sebagai alat peramalan yang otomatis dan mudah digunakan. Pendekatan ini menyederhanakan proses penyesuaian (*tuning*) metode deret waktu, sehingga dapat digunakan secara efektif oleh analis dari berbagai latar belakang, termasuk mereka yang memiliki pengalaman terbatas dalam peramalan [10].

Sebagai model yang dapat didekomposisi (*decomposable model*), Prophet bekerja dengan menguraikan data deret waktu menjadi beberapa komponen penyusun yang lebih sederhana. Komponen-komponen utama yang dipertimbangkan oleh Prophet, sebagaimana ditunjukkan pada Persamaan 1 [11].

$$Y_t = G_t + S_t + H_t + et \quad (1)$$

Dengan G_t adalah komponen tren, S_t adalah komponen musiman, H_t adalah efek hari libur, dan et adalah komponen *error rate*.

2.7. XGBoost

Extreme Gradient Boosting (XGBoost) merupakan algoritma *ensemble learning* berbasis Classification And Regression Tree (CART) yang bekerja dengan menggabungkan banyak model pohon berakurasi rendah melalui proses iteratif hingga membentuk model dengan akurasi tinggi. XGBoost dikenal memiliki kecepatan pelatihan yang tinggi, hasil prediksi yang akurat, serta tidak membutuhkan persyaratan data yang terlalu ketat [12].

Pada metode ini, diperlukan suatu fungsi objektif yang berperan untuk menilai seberapa baik model mampu mempelajari pola dari data latih [13]. Fungsi objektif XGBoost terdiri atas dua komponen utama, yaitu *loss function* yang mengukur error prediksi dan *regularization* yang berfungsi mengontrol kompleksitas model. Persamaan dasar prediksi tersebut dapat dilihat pada Persamaan 2 [14].

$$\hat{y}_i = \sum_{j=1}^k f_j(X_i), \quad f_j \in F \quad (2)$$

Di mana $f(x)$ merupakan himpunan fungsi CART pada kerangka XGBoost, F adalah ruang fungsi pohon keputusan, dan setiap fungsi pohon memiliki struktur daun dengan bobot tertentu. Setiap pohon dibangun secara independen pada setiap iterasi untuk memperbaiki kesalahan model sebelumnya [14]. Proses pembelajaran XGBoost dilakukan dengan meminimalkan fungsi objektif yang diregularisasi dapat dilihat pada Persamaan 3.

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)}) + \Omega(f_t) \quad (3)$$

Di mana l adalah *convex loss function* yang mengukur selisih antara nilai aktual y_i dan nilai prediksi $\hat{y}_i$, t menunjukkan iterasi ke- t , sementara $\Omega(f_t)$ merupakan istilah regularisasi yang membatasi kompleksitas pohon. Dengan memasukkan regularisasi, XGBoost mampu mengurangi risiko *overfitting* dan menghasilkan model yang lebih general [14].

2.8. Multi-Layer Perceptron (MLP)

Multilayer Perceptron (MLP) merupakan salah satu jenis *artificial neural network* yang banyak digunakan pada tugas *supervised learning*, baik untuk klasifikasi maupun regresi. Nilai bobot (*weights*) dalam proses pelatihan diperbarui secara bertahap hingga jaringan mencapai kondisi optimal, sehingga proses pelatihan dapat dihentikan pada waktu yang tepat [15]. MLP banyak diterapkan di berbagai bidang karena kemampuannya dalam mempelajari hubungan nonlinier dan memprediksi variabel kategori maupun numerik dengan tingkat akurasi yang tinggi [16].

Secara umum, perhitungan sinyal *output* pada MLP melibatkan bobot, nilai bias, dan input, seperti ditunjukkan pada Persamaan 4 [17].

$$S_i = \sum_{i=1}^n w_{ij} I_i + \beta_i \quad (4)$$

Di mana I merupakan lapisan *input*, I_i adalah variabel input ke- i , n adalah jumlah *input*, β_i merupakan nilai bias, dan w_{ij} adalah bobot koneksi pada level ke- j .

Untuk menghasilkan sinyal aktivasi, MLP umumnya menggunakan fungsi aktivasi sigmoid yang ditunjukkan pada Persamaan 5 [17].

$$F_j = \frac{1}{1 + e^{-s_j}} \quad (5)$$

Fungsi aktivasi tersebut mentransformasikan sinyal menjadi nilai output pada neuron. Nilai output akhir dari neuron ke- j dapat dihitung menggunakan Persamaan 6 [17].

$$y_i = F_j \left(\sum_{i=1}^n w_{ij} I_i + \beta_i \right) \quad (6)$$

Di mana y merupakan keluaran akhir yang kemudian dibandingkan dengan nilai target untuk mengukur kinerja model selama proses pelatihan.

2.9. Evaluasi

Proses evaluasi merupakan tahapan yang sangat penting dalam pengembangan model *machine learning*. Evaluasi berfungsi untuk menilai sejauh mana model yang dibangun mampu memberikan hasil prediksi yang akurat berdasarkan data dan parameter yang digunakan [18]. Pada penelitian ini, proses evaluasi dilakukan menggunakan metrik MAE, RMSE, MAPE, dan R^2 , yang secara umum banyak digunakan dalam model regresi untuk mengukur tingkat kesalahan dan kemampuan model dalam menjelaskan variansi data.

2.9.1. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan salah satu metrik yang digunakan untuk menilai tingkat akurasi model peramalan. MAE menghitung rata-rata selisih absolut antara nilai aktual dan nilai prediksi, sehingga memberikan gambaran seberapa besar kesalahan rata-rata yang dihasilkan model dalam satuan yang sama dengan data aslinya [19]. Karena hanya bergantung pada selisih absolut, MAE bersifat stabil dan tidak terlalu sensitif terhadap nilai ekstrem. Namun demikian, apabila data uji memiliki banyak *outlier*, maka performa model cenderung menurun dan nilai MAE menjadi kurang

optimal [20]. Perhitungan MAE ditunjukkan pada Persamaan 7.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - F_i| \quad (7)$$

Di mana n merupakan jumlah data, Y_i merupakan nilai aktual, F_i merupakan nilai prediksi dari model untuk observasi ke- i .

2.9.2. Root Mean Absolute Error (RMSE)

Root Mean Squared Error (RMSE) merupakan metrik evaluasi yang dihitung sebagai akar kuadrat dari Mean Squared Error (MSE). RMSE mengukur seberapa besar rata-rata kesalahan prediksi yang terjadi dengan memberikan penalti lebih besar terhadap *error* yang bernilai besar. Semakin rendah nilai RMSE, maka semakin baik kualitas prediksi yang dihasilkan model [21]. Perhitungan dari rumus RMSE dapat dilihat pada Persamaan 8.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (8)$$

Di mana n merupakan jumlah data, y'_i merupakan nilai prediksi dari data ke- i , dan y_i merupakan nilai sebenarnya data ke- i .

2.9.3. MAPE

Mean Absolute Percentage Error (MAPE) merupakan salah satu metrik kinerja yang digunakan dalam model regresi dan memiliki interpretasi yang intuitif dalam hal kesalahan relatif. Berdasarkan definisinya, MAPE direkomendasikan untuk digunakan pada tugas atau analisis di mana sensitivitas terhadap variasi relatif lebih penting dibandingkan variasi absolut [20].

MAPE menunjukkan persentase kesalahan hasil peramalan terhadap data aktual pada periode tertentu. Nilai MAPE memberikan informasi mengenai seberapa besar tingkat kesalahan prediksi yang terjadi apakah termasuk tinggi atau rendah. Rumus dari perhitungan MAPE dapat dilihat pada Persamaan 9 [22].

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \quad (9)$$

Dengan keterangan bahwa y_i merupakan nilai aktual, y'_i adalah nilai hasil peramalan, dan n menunjukkan jumlah data yang digunakan.

2.9.4. Koefisien Determinasi (R^2)

Koefisien determinasi (R^2) digunakan untuk mengetahui kecocokan atau ketepatan suatu model. Nilai koefisien determinasi yaitu antara 0 sampai dengan 1 di mana jika nilai R^2 makin mendekati 1 maka pengaruh variabel bebas X terhadap variabel tidak bebas Y semakin besar [23]. Pada Persamaan 10 ditunjukkan formula untuk menghitung koefisien determinasi.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

Di mana R^2 merupakan koefisien determinasi, y merupakan nilai aktual, $\hat{y}$ merupakan nilai hasil prediksi, $\bar{y}$ merupakan nilai rata-rata aktual deviasi dari variabel tidak bebas, dan n menunjukkan jumlah sampel yang digunakan.

3. Hasil Percobaan

3.1. Hasil Modeling

Pada tahap ini, dilakukan perbandingan kinerja antara model Prophet, XGBoost, dan MLP Regressor. Setiap model dilatih dan dievaluasi menggunakan data uji pada kedua skema pembagian data (80:20 dan 70:30). Kinerja model diukur menggunakan metrik MAE, RMSE, MAPE (Mean Absolute Percentage Error), dan R^2 (R-squared).


3.1.1. Prophet

Model Prophet, sebagai model khusus deret waktu, dilatih langsung menggunakan data latih (train_1 untuk skema 80:20 dan train_2 untuk skema 70:30) yang terdiri dari kolom ds (tanggal) dan y (kurs), tanpa memerlukan proses rekayasa fitur tambahan. Proses pelatihan dilakukan menggunakan konfigurasi default Prophet. Prediksi untuk periode data uji dihasilkan melalui fungsi `make_future_dataframe` dengan parameter `freq='D'` (harian). Hasil prediksi mentah yang mencakup seluruh hari, termasuk akhir pekan, kemudian disesuaikan dengan data aktual yang hanya mencakup hari kerja berdasarkan kolom tanggal (ds) sebelum dilakukan evaluasi metrik.

Pada skema 80:20, pelatihan model Prophet menggunakan 1.160 data latih memerlukan waktu sekitar 0,78 detik, sedangkan proses prediksi berlangsung selama 0,44 detik. Evaluasi terhadap 282 data uji (setelah penyelarasan) menghasilkan MAE sebesar Rp847,95, RMSE sebesar Rp920,94, dan MAPE sebesar 5,34%. Namun, nilai R^2 yang sangat negatif (-3,2238) menunjukkan bahwa model tidak mampu menjelaskan variansi data uji dengan baik.

Gambar 2 memperlihatkan bahwa hasil prediksi Prophet (garis hitam) cenderung datar atau sedikit


menurun, sangat kontras dengan data aktual (merah) yang menunjukkan lonjakan tajam. Ketidaksesuaian ini sejalan dengan nilai R^2 negatif, menandakan bahwa model gagal menangkap pola fluktuasi kurs pada periode pengujian.



Gambar 2 Prediksi Model Prophet dengan skema 80:20

Pada skema 70:30, pelatihan pada 1.015 data latih memakan waktu 1,51 detik, dengan waktu prediksi yang sama yaitu 0,44 detik. Hasil evaluasi pada 423 data uji (setelah penyelarasan) menunjukkan MAE sebesar Rp581,51, RMSE sebesar Rp743,55, dan MAPE sebesar 3,62%. Meskipun nilai MAE dan MAPE menunjukkan peningkatan akurasi dibandingkan skema 80:20, nilai R^2 kembali negatif (-3,9476).

Gambar 3 menampilkan pola prediksi Prophet masih gagal mengikuti tren kenaikan nilai kurs aktual. Hasil ini menegaskan bahwa dengan konfigurasi default, Prophet belum mampu beradaptasi terhadap perubahan tren yang tajam serta volatilitas tinggi pada data kurs USD/IDR, terutama untuk horizon prediksi yang lebih panjang.



Gambar 3 Prediksi Model Prophet dengan skema 70:30


3.1.2. XGBoost

Berbeda dengan Prophet, model XGBoost diterapkan pada dataset yang telah melalui proses rekayasa fitur, dengan total 12 variabel prediktor (X_{train_1} dan X_{train_2}) untuk memprediksi target y (kurs). Model dilatih menggunakan konfigurasi dasar, yaitu `n_estimators=1000` dan `learning_rate=0.01`, serta

menerapkan mekanisme *early stopping* (`early_stopping_rounds=50`) dengan data uji sebagai set evaluasi untuk mencegah overfitting.

Pada skema 80:20, pelatihan XGBoost pada 1.125 data latih berfitur berlangsung selama 2,05 detik, sedangkan prediksi terhadap 282 data uji hanya membutuhkan 0,01 detik. Evaluasi menunjukkan hasil yang jauh lebih baik dibandingkan Prophet, dengan MAE sebesar Rp100,60, RMSE sebesar Rp153,18, MAPE sebesar 0,62%, dan R^2 sebesar 0,8603.


Gambar 4 menampilkan visualisasi hasil prediksi XGBoost yang menunjukkan kesesuaian tinggi dengan data aktual. Garis prediksi (merah) mampu mengikuti fluktuasi nilai kurs aktual (biru) dengan baik, termasuk pada saat terjadi lonjakan harga. Nilai R^2 yang mendekati 1 menunjukkan bahwa model ini mampu menjelaskan sekitar 86% variansi data uji.



Gambar 4 Prediksi Model Prophet dengan skema 80:20

Untuk skema 70:30, pelatihan pada 984 data latih memerlukan waktu 2,22 detik, sedangkan prediksi terhadap 423 data uji tetap cepat, yaitu 0,02 detik. Evaluasi menghasilkan MAE sebesar Rp380,11, RMSE sebesar Rp475,21, MAPE sebesar 2,33%, dan R^2 sebesar -0,4434.

Gambar 5 memperlihatkan bahwa meskipun model masih mampu mengikuti pola data pada awal periode uji, performanya mulai menurun pada bagian akhir, ditandai dengan divergensi antara garis prediksi dan data aktual. Hasil ini mengindikasikan bahwa meskipun XGBoost sangat kuat untuk peramalan jangka pendek, akurasi cenderung menurun seiring bertambahnya horizon waktu prediksi.



Gambar 5 Prediksi Model Prophet dengan skema 70:30


3.1.3. MLP

Model ketiga yang diuji adalah MLP Regressor, yang diimplementasikan sebagai model supervised learning dengan menggunakan 12 fitur yang sama seperti pada XGBoost (`X_train_1`, `y_train_1` dan `X_train_2`, `y_train_2`). Mengingat sensitivitas jaringan saraf tiruan terhadap skala fitur, model ini diterapkan melalui Pipeline yang secara otomatis melakukan standarisasi fitur menggunakan `StandardScaler` sebelum data dimasukkan ke dalam MLP Regressor.

Arsitektur jaringan yang digunakan merupakan konfigurasi dasar dengan dua hidden layer berisi masing-masing 100 dan 50 neuron, fungsi aktivasi ReLU, algoritma Adam, serta jumlah iterasi maksimum sebanyak 500. Mekanisme *early stopping* juga diaktifkan untuk meningkatkan efisiensi proses pelatihan.

Pada skema 80:20, proses pelatihan pipeline MLP terhadap 1.125 data latih berfitur membutuhkan waktu 7,31 detik, lebih lama dibandingkan XGBoost. Namun, waktu prediksi pada 282 data uji tetap sangat singkat, yaitu 0,01 detik. Hasil evaluasi menunjukkan MAE sebesar Rp1.236,95, RMSE sebesar Rp1.447,42, MAPE sebesar 7,61%, dan R^2 sebesar -11,4704.

Gambar 6 memperlihatkan hasil visualisasi prediksi MLP dibandingkan data aktual untuk skema 80:20. Terlihat bahwa garis prediksi MLP (hijau putus-putus) cenderung datar dan gagal mengikuti fluktuasi nilai aktual (biru). Nilai R^2 yang sangat negatif menunjukkan bahwa model tidak mampu menangkap pola data dengan baik, menandakan adanya *underfitting* yang cukup parah. Dengan kata lain, konfigurasi dasar MLP ini belum cukup mampu mempelajari hubungan antara fitur dan target yang diberikan.




Gambar 6 Prediksi Model Prophet dengan skema 80:20

Pada skema 70:30, pelatihan MLP terhadap 984 data latih berfitur membutuhkan waktu 4,99 detik, sedikit lebih cepat dibandingkan skema sebelumnya, kemungkinan karena mekanisme *early stopping* terpicu lebih awal. Waktu prediksi untuk 423 data uji tetap cepat, yaitu 0,02 detik. Namun, hasil evaluasi menunjukkan penurunan performa yang cukup signifikan dengan MAE sebesar Rp5.643,00, RMSE sebesar Rp6.352,17, MAPE sebesar 34,75%, dan R^2 sebesar -256,9047.

Gambar 7 menunjukkan bahwa prediksi MLP (garis hijau) kembali terlihat datar dan tidak mengikuti pola pergerakan data aktual (biru). Nilai-nilai metrik yang sangat buruk ini menegaskan bahwa model MLP mengalami kegagalan total dalam melakukan peramalan pada horizon waktu yang lebih panjang.

Secara keseluruhan, performa MLP pada kedua skema menunjukkan bahwa jaringan saraf dasar tanpa penyesuaian arsitektur atau *hyperparameter tuning* yang tepat belum efektif untuk memodelkan data kurs harian USD/IDR, bahkan ketika menggunakan fitur yang sama dengan model XGBoost yang menunjukkan hasil jauh lebih baik.



Gambar 7 Prediksi Model Prophet dengan skema 70:30

3.2. Perbandingan Performa Model

Untuk membandingkan kinerja ketiga model (Prophet, XGBoost, dan MLP) secara keseluruhan, hasil evaluasi metrik dari kedua skema pembagian data (80:20 dan 70:30) dirangkum dalam Tabel 2.

Tabel 2 Perbandingan Metrik Evaluasi Kinerja Model

Skema	Algoritma	MAE	RMSE	MAPE	R^2
80:20	Prophet	847.95	920.94	5.34%	-3.2238
	XGBoost	100,60	153,18	0,62%	0,8603
	MLP	1236.95	1447.42	7.61%	-11.4704
70:30	Prophet	581.51	743.55	3.62%	-3.9476
	XGBoost	380,11	475,21	2,33%	-0,4434
	MLP	5643	6352.17	34.75%	-256.9047

Berdasarkan Tabel 2, dapat terlihat dengan jelas bahwa XGBoost memberikan performa terbaik secara signifikan, terutama pada skema 80:20. Dengan nilai MAE hanya sebesar Rp100,60 dan MAPE sebesar 0,62%, XGBoost menunjukkan tingkat kesalahan prediksi yang jauh lebih rendah dibandingkan Prophet (MAE Rp847,95) maupun MLP (MAE Rp1.236,95) pada skema yang sama. Selain itu, nilai R^2 positif sebesar 0,8603 menegaskan kemampuan XGBoost dalam menjelaskan sebagian besar variansi pada data uji, sementara Prophet dan MLP justru menghasilkan R^2 negatif yang sangat besar, menandakan bahwa kinerja keduanya lebih buruk daripada model *baseline*.

Temuan ini memperkuat kesimpulan bahwa pendekatan *supervised learning* yang disertai dengan rekayasa fitur, ketika diterapkan menggunakan model ensemble tree seperti XGBoost, terbukti lebih efektif dalam menangkap dinamika serta volatilitas data kurs harian USD/IDR. Sebaliknya, model time series spesialis seperti Prophet dan model jaringan saraf dasar (MLP) dengan konfigurasi standar belum mampu memberikan hasil yang kompetitif dalam konteks ini.

Perbandingan antara kedua skema juga memberikan wawasan yang menarik. Kinerja XGBoost mengalami penurunan ketika horizon prediksi diperpanjang, yang terlihat dari peningkatan MAE menjadi Rp380,11 dan perubahan R^2 menjadi negatif pada skema 70:30, menunjukkan bahwa model ini cukup sensitif terhadap panjang periode peramalan. Di sisi lain, Prophet justru menunjukkan nilai MAE dan MAPE yang lebih baik pada skema 70:30 dibandingkan 80:20, meskipun nilai R^2 tetap negatif dan bahkan semakin memburuk, menandakan bahwa peningkatan tersebut tidak diikuti oleh kemampuan penjelasan yang lebih baik terhadap data. Sementara itu, kinerja MLP menurun secara drastis pada skema 70:30, dengan MAE melonjak hingga Rp5.643,00, yang menegaskan ketidakmampuan model ini dalam melakukan peramalan jangka panjang tanpa penyesuaian arsitektur atau *hyperparameter tuning* yang lebih optimal.

Selain dari sisi akurasi, aspek efisiensi komputasi juga perlu diperhatikan. Tabel 3 merangkum waktu yang dibutuhkan setiap model dalam proses pelatihan (*training time*) dan pembuatan prediksi (*prediction time*), yang dapat menjadi pertimbangan tambahan dalam

mengevaluasi kelayakan penerapan masing-masing model pada skenario operasional yang berbeda

Tabel 3 Perbandingan Waktu Komputasi Tiap Model

Skema	Algoritma	Waktu Pelatihan (detik)	Waktu Prediksi (detik)
80:20	Prophet	0,78	0,44
	XGBoost	2,05	0,01
	MLP	7,31	0,01
70:30	Prophet	1,51	0,44
	XGBoost	2,22	0,02
	MLP	4,99	0,02

Tabel 3 menunjukkan bahwa Prophet memiliki waktu pelatihan tercepat pada skema 80:20, namun waktu prediksinya paling lama. XGBoost dan MLP menunjukkan waktu prediksi yang sangat cepat (0,01-0,02 detik). Meskipun waktu pelatihan XGBoost (sekitar 2 detik) sedikit lebih lama dari Prophet (pada skema 80:20), namun jauh lebih cepat dibandingkan MLP (sekitar 5-7 detik). Mengingat keunggulan akurasi XGBoost yang sangat signifikan, *trade-off* waktu pelatihan yang sedikit lebih lama ini sangat dapat diterima, menjadikannya model dengan keseimbangan terbaik antara akurasi dan efisiensi komputasi dalam penelitian ini, terutama untuk prediksi jangka pendek.

4. Kesimpulan

Peramalan nilai tukar, khususnya kurs USD/IDR, memiliki peran penting dalam mendukung stabilitas ekonomi makro serta proses pengambilan keputusan di sektor bisnis dan keuangan. Tingginya volatilitas kurs dan kompleksitas faktor yang memengaruhinya menjadikan prediksi yang akurat sebagai kebutuhan strategis. Pendekatan *machine learning* memberikan alternatif berbasis data yang lebih adaptif untuk memahami pergerakan kurs harian.

Penelitian ini membandingkan tiga pendekatan pemodelan, yaitu Prophet, XGBoost, dan Multi-Layer Perceptron (MLP) Regressor dalam memprediksi kurs tengah harian USD/IDR menggunakan data historis JISDOR dari Oktober 2019 hingga Oktober 2025. Evaluasi dilakukan pada dua skema pembagian data (80:20 dan 70:30) menggunakan metrik MAE, RMSE, MAPE, dan R^2 . Hasil analisis menunjukkan beberapa poin utama sebagai berikut:

1. Pendekatan *supervised learning* berbasis rekayasa fitur terbukti lebih efektif dalam menangkap pola kurs harian dibandingkan pendekatan *time series* murni. Transformasi deret waktu menjadi format *supervised learning*, melalui pembuatan fitur lag, *rolling statistics*, dan fitur kalender, memberikan nilai tambah signifikan ketika dipadukan dengan model XGBoost.
2. XGBoost menjadi model dengan performa paling unggul. Pada skema 80:20, XGBoost menghasilkan MAE terendah (Rp 100,60), MAPE terendah (0,62%), serta menjadi satu-

satunya model dengan penililai R^2 positif (0,8603). Visualisasi juga menunjukkan bahwa model ini mampu mengikuti pola aktual dengan sangat baik.

3. Prophet dan MLP menunjukkan keterbatasan pada data dengan volatilitas tinggi. Prophet cenderung kurang adaptif terhadap perubahan tren dan menghasilkan nilai R^2 negatif pada kedua skema. Sementara itu, MLP dengan konfigurasi dasar mengalami *underfitting* dan menghasilkan error tertinggi, mengindikasikan bahwa model ini belum optimal untuk tugas ini tanpa desain arsitektur yang lebih kompleks.
4. Horizon prediksi memengaruhi kinerja model. Akurasi XGBoost menurun pada skema 70:30, menegaskan bahwa model ini lebih andal untuk prediksi jangka pendek. Prophet menunjukkan sedikit perbaikan pada horizon yang lebih panjang, tetapi secara keseluruhan tetap kurang akurat. Kinerja MLP justru menurun drastis pada horizon prediksi yang lebih jauh.
5. Dari sisi efisiensi, XGBoost juga menawarkan keseimbangan terbaik antara akurasi dan kecepatan. Waktu pelatihannya masih wajar dan proses prediksi berlangsung sangat cepat. Sebaliknya, MLP membutuhkan waktu pelatihan paling lama, sementara Prophet unggul dalam kecepatan tetapi jauh tertinggal dalam akurasi.

Penelitian ini masih memiliki beberapa keterbatasan, seperti penggunaan *hyperparameter* default, belum dieksplorasi variabel eksternal (seperti indikator ekonomi global), serta fokus pada satu pasangan mata uang. Pengembangan selanjutnya dapat mencakup optimasi *hyperparameter*, pemanfaatan arsitektur *deep learning* yang lebih maju, penambahan variabel eksternal, serta pengujian pada pasangan mata uang lain.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa XGBoost merupakan metode paling menjanjikan untuk peramalan kurs harian USD/IDR, terutama untuk kebutuhan prediksi jangka pendek.

REFERENSI

- [1] H. H. Alwi and L. Nirawati, "Pengaruh Inflasi, Suku Bunga Bank Indonesia, dan Nilai Tukar Rupiah (USD/IDR) terhadap Indeks Saham Bisnis-27 di Bursa Efek Indonesia (BEI)," *Al-Kharaj: Jurnal Ekonomi, Keuangan & Bisnis Syariah*, vol. 5, no. 2, pp. 620–635, Aug. 2022, doi: 10.47467/alkharaj.v5i2.1242.
- [2] W. Khamidah and R. Sugiharti, "Faktor yang Mempengaruhi Nilai Tukar Rupiah Terhadap Dolar Amerika, Euro dan Poundsterling," *Ecoplan*, vol. 5, no. 1, pp. 40–52, Apr. 2022, doi: 10.20527/ecoplan.v5i1.425.
- [3] A. Wijaya and I. Fenriana, "Prediksi Harga Saham Top 10 NASDAQ dengan Time Series Prophet," *bit-Tech*, vol. 7, no. 2, pp. 252–262, Dec. 2024, doi: 10.32877/bt.v7i2.1736.
- [4] R. S. Santoso and F. K. Sari Dewi, "Konfigurasi Model Prophet Untuk Prediksi Harga Saham Sektor Teknologi di Indonesia Yang Akurat," *Jurnal Buana Informatika*, vol.

- 15, no. 01, pp. 50–58, Apr. 2024, doi: 10.24002/jbi.v15i1.8634.
- [5] Y. Zhang, “Stock Price Prediction Method Based on XGBoost Algorithm,” 2023, pp. 595–603. doi: 10.2991/978-94-6463-030-5_60.
- [6] K. H. Suradiradja, “Algoritme Machine Learning Multi-Layer Perceptron dan Recurrent Neural Network untuk Prediksi Harga Cabai Merah Besar di Kota Tangerang,” *Faktor Exacta*, vol. 14, no. 4, p. 194, Jan. 2022, doi: 10.30998/faktorexacta.v14i4.10376.
- [7] P. B. Guruge and Y. H. P. P. Priyadarshana, “Time series forecasting-based Kubernetes autoscaling using Facebook Prophet and Long Short-Term Memory,” *Front Comput Sci*, vol. 7, Feb. 2025, doi: 10.3389/fcomp.2025.1509165.
- [8] T. Verdonck, B. Baesens, M. Öskarsdóttir, and S. vanden Broucke, “Special issue on feature engineering editorial,” *Mach Learn*, vol. 113, no. 7, pp. 3917–3928, Jul. 2024, doi: 10.1007/s10994-021-06042-2.
- [9] Y. A. Prasetyo, E. Utami, and A. Yaqin, “Pengaruh Komposisi Split Data Terhadap Performa Akurasi Analisis Sentimen Algoritma Naïve Bayes dan SVM,” *Journal of Electrical Engineering and Computer (JEECOM)*, vol. 6, no. 2, pp. 382–390, Oct. 2024, doi: 10.33650/jeeecom.v6i2.9188.
- [10] C. B. Aditya Satrio, W. Darmawan, B. U. Nadia, and N. Hanafiah, “Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET,” *Procedia Comput Sci*, vol. 179, pp. 524–532, 2021, doi: 10.1016/j.procs.2021.01.036.
- [11] S. L. Sheeba, N. Gupta, R. M. A. Ragavender, and D. Divya, “Time series model for stock market prediction utilising prophet,” *Turkish Journal of Computer and Mathematics Education*, vol. 12, no. 6, pp. 4529–4534, 2021.
- [12] X. Guan *et al.*, “Construction of the XGBoost model for early lung cancer prediction based on metabolic indices,” *BMC Med Inform Decis Mak*, vol. 23, no. 1, p. 107, Jun. 2023, doi: 10.1186/s12911-023-02171-x.
- [13] I. Hanif, “Implementing Extreme Gradient Boosting (XGBoost) Classifier to Improve Customer Churn Prediction,” in *Proceedings of the Proceedings of the 1st International Conference on Statistics and Analytics, ICSA 2019, 2-3 August 2019, Bogor, Indonesia*, EAI, 2020. doi: 10.4108/eai.2-8-2019.2290338.
- [14] B. Ma, G. Yan, B. Chai, and X. Hou, “XGBLC: an improved survival prediction model based on XGBoost,” *Bioinformatics*, vol. 38, no. 2, pp. 410–418, Jan. 2022, doi: 10.1093/bioinformatics/btab675.
- [15] A. Ostovar, D. D. Davari, and M. Dzikuć, “Determinants of Design with Multilayer Perceptron Neural Networks: A Comparison with Logistic Regression,” *Sustainability*, vol. 17, no. 6, p. 2611, Mar. 2025, doi: 10.3390/su17062611.
- [16] A. Sumayli, “Development of advanced machine learning models for optimization of methyl ester biofuel production from papaya oil: Gaussian process regression (GPR), multilayer perceptron (MLP), and K-nearest neighbor (KNN) regression models,” *Arabian Journal of Chemistry*, vol. 16, no. 7, p. 104833, Jul. 2023, doi: 10.1016/j.arabjc.2023.104833.
- [17] S. Nosratabadi, S. Ardabili, Z. Lakner, C. Mako, and A. Mosavi, “Prediction of Food Production Using Machine Learning Algorithms of Multilayer Perceptron and ANFIS,” *Agriculture*, vol. 11, no. 5, p. 408, May 2021, doi: 10.3390/agriculture11050408.
- [18] A. D. Sidik and A. Ansawarman, “Prediksi Jumlah Kendaraan Bermotor Menggunakan Machine Learning,” *Formosa Journal of Multidisciplinary Research*, vol. 1, no. 3, pp. 559–568, Jul. 2022, doi: 10.55927/fjmr.v1i3.745.
- [19] M. Muharrom, “Analisis Komparasi Algoritma Data Mining Naive Bayes, K-Nearest Neighbors dan Regresi Linier Dalam Prediksi Harga Emas,” *Bulletin of Information Technology (BIT)*, vol. 4, no. 4, pp. 430–438, Dec. 2023, doi: 10.47065/bit.v4i4.986.
- [20] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput Sci*, vol. 7, p. e623, Jul. 2021, doi: 10.7717/peerj-cs.623.
- [21] A. N. Maharadja, I. Maulana, and B. A. Dermawan, “Penerapan Metode Regresi Linear Berganda untuk Prediksi Kerugian Negara Berdasarkan Kasus Tindak Pidana Korupsi,” *Journal of Applied Informatics and Computing*, vol. 5, no. 1, pp. 95–102, Jul. 2021, doi: 10.30871/jaic.v5i1.3184.
- [22] M. R. Athallah and A. F. Rozi, “Implementasi Data Mining Untuk Prediksi Peramalan Penjualan Produk HJ Karpet Menggunakan Metode Linear Regression,” *Jurnal Sains dan Teknologi (JSIT)*, vol. 2, no. 3, pp. 180–187, Feb. 2023, doi: 10.47233/jsit.v2i3.550.
- [23] S. D. Puspa, J. Riyono, and F. Puspitasari, “Analisis Faktor-Faktor yang Mempengaruhi Pemahaman Konsep Matematis Mahasiswa dalam Pembelajaran Jarak Jauh Pada Masa Pandemi Covid-19,” *Jurnal Cendekia : Jurnal Pendidikan Matematika*, vol. 5, no. 1, pp. 302–320, Mar. 2021, doi: 10.31004/cendekia.v5i1.533.

Khansa Maritza Ar-Rahmah, saat ini sebagai mahasiswa Program Studi Teknik Informatika Fakultas Teknologi Informasi Universitas Tarumanagara.

Raffi Cahya Tria Putra Yasin, saat ini sebagai mahasiswa Program Studi Teknik Informatika Fakultas Teknologi Informasi Universitas Tarumanagara.