

Perbandingan Metode Dekomposisi Multiplikatif dan Metode Prophet dalam Meramalkan Nilai Tukar USD ke Rupiah

Mohammad Dwitiar Nalole¹, Agusyarif Rezka Nuha², La Ode Nashar^{1*}, Novianita Achmad³, Asriadi²

¹Program Studi Statistika, Universitas Negeri Gorontalo, Gorontalo, Indonesia

²Program Studi Matematika, Universitas Negeri Gorontalo, Gorontalo, Indonesia

³Program Studi Pendidikan Matematika, Universitas Negeri Gorontalo, Gorontalo, Indonesia

* Corresponding Author: laode.nashar@ung.ac.id

Abstrak

Nilai tukar antara USD dan Rupiah memiliki dampak signifikan terhadap perekonomian Indonesia, sehingga peramalan yang akurat menjadi sangat penting dalam pengambilan keputusan ekonomi. Penelitian ini membandingkan metode dekomposisi multiplikatif dan metode Prophet dalam meramalkan nilai tukar USD terhadap Rupiah. Data nilai tukar bulanan dari tahun 2018 hingga 2023 digunakan, dengan 80% sebagai data pelatihan dan 20% sebagai data pengujian. Model akhir untuk metode Dekomposisi Multiplikatif menggabungkan komponen tren, musiman, dan siklus secara multiplikatif, sehingga memungkinkan representasi perilaku nilai tukar yang lebih rinci dari waktu ke waktu. Sebaliknya, metode prophet menghasilkan model akhir yang menggabungkan komponen tren dan musiman secara aditif, serta mampu mengakomodasi perubahan tren secara dinamis melalui deteksi otomatis terhadap changepoints. Akurasi kedua metode dievaluasi menggunakan mean absolute percentage error (MAPE). Hasil menunjukkan bahwa metode dekomposisi multiplikatif memiliki nilai MAPE sebesar 1,21%, sedangkan metode Prophet memiliki nilai MAPE sebesar 5,43%. Temuan ini menunjukkan bahwa metode dekomposisi multiplikatif lebih akurat dalam meramalkan nilai tukar untuk periode yang diberikan, sehingga lebih sesuai untuk dataset ini yang menunjukkan pola musiman yang kuat.

The exchange rate between USD and Rupiah has a significant impact on Indonesia's economy, making accurate forecasting essential for economic decision-making. This study compares the multiplicative decomposition method and the Prophet method in forecasting the USD to Rupiah exchange rate. Monthly exchange rate data from 2018 to 2023 was used, with an 80% training set and a 20% test set. The final model for the multiplicative decomposition method combines the trend, seasonal, and cycle components multiplicatively, allowing for a detailed representation of the exchange rate's behavior over time. In contrast, the prophet method produces a final model that incorporates trend and seasonal components additively, while also accommodating dynamic changes in the trend through automatic detection of changepoints. The accuracy of both methods was evaluated using mean absolute percentage error (MAPE). Results show that the multiplicative decomposition method had a MAPE of 1.21%, while the Prophet method had a MAPE of 5.43%. These findings indicate that the multiplicative decomposition method is more accurate in forecasting the exchange rate for the given period, making it more suitable for this dataset, which exhibits strong seasonal patterns.

Kata kunci: nilai tukar; peramalan; dekomposisi multiplikatif; prophet; MAPE.

Keywords: exchange rate; forecasting; multiplicative decomposition; prophet; MAPE.

This is an open access article under the [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/)



How to Cite:

M. D. Nalole, A. R. Nuha, L. O. Nashar, N. Achmad, and Asriadi, "Perbandingan metode dekomposisi multiplikatif dan metode prophet dalam meramalkan nilai tukar USD ke rupiah," *Indonesian Journal of Applied Statistics*, vol. 8, no. 1, pp. 63-76, 2025, doi: 10.13057/ijas.v8i1.96572.

1. PENDAHULUAN

Nilai tukar merupakan salah satu indikator penting dalam perekonomian suatu negara. Pergerakan nilai tukar dipengaruhi oleh berbagai faktor, seperti suku bunga, inflasi, neraca pembayaran, serta kondisi ekonomi global [1]. Di Indonesia, nilai tukar USD ke Rupiah menjadi fokus utama karena dampaknya yang signifikan terhadap sektor perdagangan, investasi, dan harga barang impor. Perubahan nilai tukar USD ke Rupiah disebabkan oleh berbagai faktor seperti suku bunga, inflasi, dan GDP, serta kejadian tak terduga seperti pandemi COVID-19, yang semuanya berkontribusi pada ketidakstabilan nilai tukar [2]. Untuk mengantisipasi dampak fluktuasi ini, diperlukan metode peramalan yang andal untuk memberikan panduan dalam pengambilan keputusan ekonomi yang lebih baik [3].

Ketidakpastian nilai tukar USD ke Rupiah memunculkan kebutuhan akan alat peramalan yang akurat. Dalam penelitian ini, dua metode peramalan data deret waktu, yaitu dekomposisi multiplikatif dan prophet, dipertimbangkan sebagai solusi potensial. Kedua metode ini dirancang untuk mengidentifikasi pola trend dan musiman dalam data nilai tukar, sehingga mampu memberikan prediksi yang akurat. Metode dekomposisi multiplikatif merupakan pendekatan klasik yang memisahkan data deret waktu menjadi komponen *trend*, musiman, dan sisa untuk menghasilkan peramalan [4]. Selain itu metode prophet juga dapat digunakan dalam meramalkan nilai tukar USD ke Rupiah. Metode Prophet yang dikembangkan oleh Facebook menawarkan pendekatan yang lebih fleksibel dalam memodelkan komponen trend dan musiman [5].

Penelitian ini bertujuan untuk mengevaluasi keakuratan metode dekomposisi multiplikatif dan prophet dalam meramalkan nilai tukar USD ke Rupiah selama periode Januari 2018 hingga Desember 2023. Dengan menggunakan *mean absolute percentage error* (MAPE) sebagai tolok ukur akurasi, penelitian ini diharapkan dapat memberikan wawasan mengenai metode yang lebih efektif dalam memprediksi nilai tukar.

Secara teoretis, penelitian ini diharapkan dapat memberikan kontribusi pada pengembangan pemahaman tentang metode dekomposisi multiplikatif dan prophet dalam analisis deret waktu. Secara praktis, hasil penelitian ini dapat dimanfaatkan oleh institusi terkait untuk memproyeksikan nilai tukar USD ke Rupiah secara lebih akurat, mendukung stabilitas ekonomi, dan membantu dalam pengambilan keputusan strategis di sektor keuangan. Penelitian ini berupaya memberikan solusi yang efektif dalam menghadapi tantangan fluktuasi nilai tukar, sekaligus mendukung upaya pengelolaan ekonomi nasional yang lebih baik.

2. METODE

2.1. Peramalan

Peramalan berasal dari kata "ramal," yang berarti suatu kondisi yang diprediksikan akan terjadi di masa depan [6]. Peramalan merupakan proses memperkirakan apa saja yang akan dibutuhkan untuk memenuhi permintaan di masa depan, baik berupa barang maupun jasa, dengan mencakup kebutuhan dalam ukuran kuantitas, kualitas, waktu, dan lokasi [7]. Sebelum melakukan peramalan terhadap data deret waktu, data aktual harus dibagi terlebih dahulu menjadi data latih dan data uji sesuai dengan proporsi pembagian yang diinginkan oleh peneliti. Penelitian ini menggunakan data nilai tukar USD ke Rupiah periode 2020–2023, yang dibagi menjadi 80% data latih untuk membentuk model peramalan dan 20% data uji untuk mengevaluasi akurasi model.

2.2. Data Deret Waktu

Metode peramalan deret waktu memerlukan data masa lalu untuk meramalkan pola dan menentukan metode yang sesuai [8]. Pola data deret waktu terdiri dari *trend* (T), yaitu kecenderungan nilai data naik atau turun dalam jangka waktu tertentu; musiman (S), yaitu fluktuasi teratur dalam interval waktu singkat seperti tahun, bulan, atau minggu yang berulang secara konsisten; dan siklus (C),

yaitu fluktuasi teratur dalam jangka waktu lebih panjang dengan durasi yang bervariasi pada setiap siklus [9].

2.3. Metode Dekomposisi Multiplikatif

Metode dekomposisi multiplikatif adalah teknik yang digunakan untuk memisahkan komponen-komponen dalam data deret waktu, yaitu komponen *trend*, indeks musiman, dan komponen siklus, dengan tujuan untuk memahami pola dalam data dan melakukan peramalan. Metode ini mengasumsikan bahwa nilai deret waktu merupakan hasil perkalian antara ketiga komponen tersebut: indeks musiman, komponen trend, dan siklus [10].

Indeks musiman dalam data deret waktu menunjukkan pola yang berulang pada interval tertentu, seperti bulanan atau tahunan. Untuk menghitung indeks musiman, langkah pertama adalah menghitung rata-rata bergerak bulanan dengan periode 12 (MA 12), yang diperoleh dengan merata-ratakan 12 data secara berurutan. Rumus untuk menghitung rata-rata bergerak bulanan adalah sebagai berikut:

$$M_t + 0,5 = \frac{Y_{t-5} + Y_{t-4} + \dots + Y_{t-1} + Y_t + Y_{t+1} + \dots + Y_{t+5} + Y_{t+6}}{12} \quad (1)$$

dengan Y adalah data aktual pada periode tertentu. Setelah itu, rata-rata bergerak terpusat dihitung dengan merata-ratakan dua data berturut-turut:

$$M_t = \frac{M_{t-0,5} + M_{t+0,5}}{2} \quad (2)$$

Selanjutnya, komponen musiman dihitung dengan membagi data aktual pada setiap periode dengan rata-rata bergerak terpusat:

$$Kma_t = \frac{Y_{a_t}}{ma_t} \quad (3)$$

Setelah komponen musiman dihitung, langkah selanjutnya adalah menghitung rata-rata medial untuk setiap musim. Rata-rata medial dihitung dengan cara merata-ratakan nilai komponen musiman untuk periode yang sama dalam beberapa tahun. Misalnya, untuk bulan Januari, kita menghitung rata-rata nilai komponen musiman untuk bulan Januari dari berbagai tahun, seperti 2019, 2020, 2021, dan 2022. Proses ini diulang untuk setiap bulan, dari Februari hingga Desember, untuk mendapatkan nilai rata-rata musiman untuk setiap bulan sepanjang tahun. Setelah memperoleh rata-rata medial untuk setiap musim, indeks musiman dihitung untuk setiap periode. Indeks musiman ini dihitung dengan rumus berikut:

$$Ia_t = N \times \frac{Aa_t}{n} \quad (4)$$

di mana Ia_t adalah indeks musiman pada periode ke- t , N adalah total musim, Aa_t adalah rata-rata medial untuk periode ke- t , dan n adalah jumlah rata-rata musim, komponen *trend* menunjukkan arah pergerakan data dalam jangka panjang, apakah mengalami peningkatan atau penurunan. Untuk menghitung komponen trend, data harus terlebih dahulu dihilangkan pengaruh musiman dengan cara menghitung data *deseasonalized*, yaitu dengan membagi data aktual dengan komponen musiman. Rumusnya adalah:

$$Dsa_t = \frac{Y_{a_t}}{Ia_t}$$

Setelah data *deseasonalized* diperoleh, komponen trend dihitung dengan menggunakan persamaan regresi linier sebagai berikut:

$$\hat{Y}_t = a + b_t \quad (6)$$

di mana a adalah intersep (nilai awal *trend*), b adalah *slope* (kemiringan) yang menunjukkan tingkat pertumbuhan trend, dan t adalah waktu atau periode yang sedang dianalisis.

Komponen siklus menggambarkan perubahan berulang yang terjadi dalam waktu tertentu, namun tidak memiliki periode tetap, seperti fluktuasi ekonomi yang dipengaruhi oleh faktor eksternal. Siklus

dihitung dengan mencari nilai residual, yaitu selisih antara data aktual dan gabungan komponen trend dan musiman. Residual dihitung dengan rumus:

$$Ra_t = \frac{Dsa_t}{\bar{Y}} \quad (7)$$

Selanjutnya, komponen siklus dihitung menggunakan *moving average* dari residual ini:

$$Ca_t = \frac{Ra_{t-1} + Ra_t + Ra_{t+1}}{3} \quad (8)$$

Setelah ketiga komponen (musiman, *trend*, dan siklus) dihitung, nilai peramalan dapat dihitung dengan metode dekomposisi multiplikatif. Nilai peramalan dihitung dengan mengalikan ketiga komponen tersebut, menggunakan rumus:

$$Xa_t = Ia_t \times \hat{Y}_t \times Ca_t \quad (9)$$

Di sini, Xa_t adalah nilai peramalan yang diperoleh dari hasil perkalian indeks musiman (Ia_t), komponen trend (Y_t), dan komponen siklus (Ca_t) [11].

2.4. Metode Prophet

Metode Prophet adalah pengembangan *open source software* oleh Tim Data Sains Facebook di tahun 2017. Di rancang agar dapat menangani data Time Series, terdapat dalam bentuk library R dan Python. Awalnya, metode prophet dibuat untuk dapat meramalkan data bisnis harian dengan mempertimbangkan dua komponen, yaitu potongan *trend* (*plecwise trends* dan beberapa musiman (*multiple seasonality*) [12].

Pada model prophet, komponen *trend* menangani perubahan jangka panjang dalam data deret waktu. Prophet menggunakan pendekatan *piecewise linear* untuk menangkap perubahan mendadak pada *trend* yang dapat terjadi pada titik-titik tertentu yang disebut *changepts*. Rumus untuk komponen *trend* dalam prophet adalah sebagai berikut:

$$g(t) = (k + a(t)^T \delta) t + (m + a(t)^T \gamma) \times y_{\text{scale}} \quad (10)$$

dengan k adalah tingkat pertumbuhan awal yang menggambarkan seberapa cepat atau lambat *trend* awalnya berubah. Sementara $a(t)^T \delta$ merupakan perubahan laju pertumbuhan setelah titik perubahan (*changept*), memungkinkan *trend* untuk berubah secara signifikan pada titik tertentu dalam waktu. m adalah intersep awal yang menggambarkan posisi *trend* pada waktu awal, dan γ adalah perubahan pada intersep setelah titik perubahan, yang menyesuaikan *trend* setelah adanya perubahan signifikan pada data.

Komponen musiman digunakan untuk menangkap pola berulang dalam data deret waktu. Prophet menggunakan fungsi Fourier untuk menangkap musiman yang lebih kompleks dan fleksibel, termasuk musiman tahunan, mingguan, atau bahkan musiman yang lebih pendek. Rumus komponen musiman dalam prophet adalah sebagai berikut:

$$s(t) = \left[\sum_{n=1}^N (a_n \sin(\frac{2\pi n t}{p})) + (b_n \cos(\frac{2\pi n t}{p})) \right] \times y_{\text{scale}} \quad (11)$$

Dalam rumus tersebut, $X(t)$ adalah fungsi Fourier yang menggambarkan musiman, yang membentuk representasi periodik dari komponen musiman. Model prophet menjumlahkan komponen trend dan musiman untuk menghasilkan peramalan keseluruhan. Rumus peramalan dengan model prophet adalah sebagai berikut:

$$y(t) = g(t) + s(t) \quad (12)$$

dengan $y(t)$ adalah nilai yang diramalkan pada periode waktu t , $g(t)$ adalah komponen *trend* yang menangkap perubahan jangka panjang, sementara $s(t)$ adalah komponen musiman yang menangkap variasi berulang dalam data [5].

2.5. Evaluasi Model

Evaluasi model diperlukan agar dapat mengetahui tingkat keakuratan hasil peramalan yang telah dilakukan dengan cara menguji kinerja modelnya. Ada beberapa metode yang dapat digunakan dalam mengevaluasi model hasil peramalan. Dalam penelitian ini, penulis menggunakan MAPE (*mean absolute percentage error*). MAPE merupakan salah satu pengukuran yang sering digunakan untuk mengevaluasi Kualitas Prediksi. MAPE menghitung nilai mutlak dari nilai aktual dan nilai prediksi.

Untuk mengevaluasi model, digunakan MAPE yang mengukur tingkat kesalahan peramalan. Rumus MAPE adalah sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100\% \quad (13)$$

Semakin kecil nilai MAPE, semakin akurat model peramalan. Kriteria akurasi MAPE adalah [13]:

- < 10% : Akurasi sangat baik.
- 10-20% : Akurasi baik.
- 20-50% : Akurasi layak.
- 50% : Akurasi buruk.

2.6. Nilai Tukar

Nilai tukar adalah suatu harga tukar untuk menukarkan mata uang yang satu dengan yang mata uang yang lain sesuai dengan kesepakatan dan regulasi yang telah ditetapkan [14]. Nilai tukar merupakan nilai atau harga dari mata uang lokal terhadap mata uang asing. Pelaku di dalam pasar internasional sangat peduli terhadap nilai tukar Valas (valuta asing) karena dapat mempengaruhi biaya serta manfaat dalam perdagangan barang, jasa, maupun aset-aset [15]. Pada penelitian ini, penulis akan mengambil data nilai tukar/kurs mata uang USD (Amerika) terhadap mata uang Rupiah (Indonesia) karena sampai saat ini, Nilai USD masih menjadi acuan utama untuk seluruh mata uang yang ada di dunia serta acuan utama dalam penukaran uang di dunia. Negara Amerika terkenal dengan pasar keuangannya yang sudah matang sehingga membuat mata uang USD semakin unggul. Mata uang negara lain dan alat pembayaran yang lain sangat dibutuhkan untuk perekonomian Indonesia dalam membiayai transaksi ekonomi keuangan internasional (ekspor-impor).

2.7. Data Penelitian dan Pengolahan

Penelitian ini dilaksanakan di Laboratorium Komputasi Statistika, Jurusan Matematika, Universitas Negeri Gorontalo, dengan menggunakan data nilai tukar USD ke Rupiah yang dicatat setiap tanggal 1 pada awal bulan, mencakup periode dari Januari 2018 hingga Desember 2023, dengan total 72 data bulanan. Data tersebut diperoleh dari situs web resmi Yahoo Finance. Subjek penelitian mencakup seluruh data nilai tukar selama periode penelitian, dengan analisis dilakukan menggunakan perangkat lunak R Studio. Dengan pendekatan ini, hasil penelitian diharapkan dapat memberikan rekomendasi praktis bagi pengambil kebijakan untuk menghadapi ketidakpastian ekonomi global dan mengelola dampak fluktuasi nilai tukar terhadap perekonomian Indonesia.

2.8. Prosedur Pengolahan Data

Prosedur penelitian ini dilakukan dalam beberapa tahapan sebagai berikut:


- 1) Menginput data nilai tukar USD terhadap Rupiah untuk periode Januari 2018 hingga Desember 2023.
- 2) Membuat diagram pencar (*scatter plot*) untuk mengidentifikasi pola musiman dan *trend* dalam data.
- 3) Membagi data menjadi data latih dan data uji.
- 4) Menerapkan metode dekomposisi multiplikatif dan metode prophet pada data latih.
- 5) Menghitung akurasi hasil peramalan menggunakan MAPE.
- 6) Membandingkan hasil peramalan antara metode dekomposisi multiplikatif dan prophet.
- 7) Menentukan metode yang paling akurat dalam meramalkan nilai tukar USD terhadap Rupiah.

3. HASIL DAN PEMBAHASAN

3.1. Statistik Deskriptif

Penelitian ini mengeksplorasi peramalan nilai tukar USD ke Rupiah dari Januari 2018 hingga Desember 2023 dengan menggunakan metode dekomposisi multiplikatif dan metode prophet untuk menganalisis komponen *trend* dan musiman. Data nilai tukar USD ke Rupiah terdiri dari 72 observasi bulanan. Data ini dibagi menjadi data latih (80% dari total data) dan data uji (20%), dengan data latih mencakup periode Januari 2018 hingga September 2022, dan data uji mencakup Oktober 2022 hingga Desember 2023.

Pada data nilai tukar USD ke Rupiah terdapat pola *trend* dan musiman yang dapat dilihat pada Gambar 1:



Gambar 1. Plot data nilai tukar USD ke Rupiah

Pada Gambar 1 dapat dilihat bahwa data nilai tukar USD ke Rupiah memiliki pola *trend* di grafik keempat dan nilai musiman di grafik ketiga sehingga data nilai tukar USD ke Rupiah dapat digunakan dalam penelitian ini.

3.2. Metode Dekomposisi Multiplikatif

1) Indeks Musiman

Indeks musiman dalam data deret waktu menunjukkan pola yang berulang pada interval tertentu, seperti bulanan atau tahunan. Untuk menghitung komponen musiman, diperlukan beberapa langkah yang melibatkan rata-rata bergerak, komponen musiman, dan rata-rata medial. Berikut adalah langkah-langkah perhitungan komponen musiman:

a) Rata-rata Bergerak Bulanan

Langkah pertama dalam identifikasi pola musiman adalah menghitung rata-rata bergerak bulanan dengan periode 12 atau dikenal sebagai MA (12). Rata-rata bergerak ini diperoleh dengan merata-ratakan 12 data secara berurutan dan menempatkannya pada baris bagian tengah dari data yang dihitung. Untuk persamaannya dapat dilihat pada persamaan (1). Keseluruhan nilai rata-rata bergerak bulanan dapat dilihat pada Tabel 1:

Tabel 1. Rata-rata bergerak bulanan

Bulan	2018	2019	2020	2021	2022
Januari		14436,90	14465,60	14388,80	14400,55
Februari		14416,55	14509,94	14365,70	14434,41
Maret		14375,97	14537,91	14336,26	14485,12
April		14319,29	14590,84	14295,39	
Mei		14230,12	14629,18	14259,96	

Bulan	2018	2019	2020	2021	2022
Juni	14179,98	14207,03	14639,07	14270,79	
Juli	14256,48	14157,19	14640,16	14299,12	
Agustus	14302,11	14143,08	14646,93	14341,33	
September	14338,65	14152,75	14628,66	14366,56	
Oktober	14379,07	14332,96	14479,45	14345,39	
November	14409,94	14413,53	14411,23	14351,38	
Desember	14449,57	14425,34	14389,02	14373,86	

b) Rata-Rata Bergerak Terpusat

Karena panjang periode musiman adalah genap, rata-rata bergerak ini perlu dirata-ratakan kembali menggunakan dua data berurutan. Untuk persamaannya dapat dilihat pada persamaan (2). Keseluruhan nilai rata-rata bergerak terpusat dapat dilihat pada Tabel 2:

Tabel 2. Rata-rata bergerak terpusat

Bulan	2018	2019	2020	2021	2022
Januari		14426,72	14487,77	14377,25	14417,48
Februari		14396,26	14523,92	14350,98	14459,76
Maret		14347,63	14564,37	14315,82	
April		14274,71	14610,01	14277,67	
Mei		14218,58	14634,13	14265,37	
Juni	14218,23	14182,11	14639,62	14284,96	
Juli	14279,29	14150,14	14643,54	14320,23	
Agustus	14320,38	14147,92	14637,79	14353,94	
September	14358,86	14242,86	14554,05	14355,98	
Oktober	14394,50	14373,24	14445,34	14348,39	
November	14429,75	14419,43	14400,13	14362,62	
Desember	14443,23	14445,47	14388,91	14387,20	

Hasil dari rata-rata bergerak terpusat ini akan menjadi dasar untuk perhitungan nilai komponen musiman pada langkah selanjutnya.

c) Komponen Musiman

Nilai komponen musiman diperoleh dengan membagi data aktual pada setiap periode dengan rata-rata bergerak terpusat. Untuk persamaannya dapat dilihat pada persamaan (3). Keseluruhan komponen musiman dapat dilihat pada Tabel 3:

Tabel 3. Komponen musiman

Bulan	2018	2019	2020	2021	2022
Januari		1,0023065	0,9568071	0,9650663	0,9859560
Februari		0,9677236	0,9475608	0,9646395	0,9924091
Maret		0,9893969	0,9826376	0,9843832	
April		0,9970782	1,1222101	1,0229259	
Mei		1,0047420	1,0422759	1,0118347	
Juni	0,9792713	1,0152933	0,9932442	0,9992470	
Juli	0,9995594	0,9979408	0,9973134	1,0196486	
Agustus	1,0062024	1,0012074	1,0040450	1,0045810	
September	1,0273101	1,0014846	1,0031365	0,9923743	
Oktober	1,0352562	0,9894706	1,0284979	1,0012623	
November	1,0531018	0,9796503	1,0129196	0,9859621	
Desember	0,9941334	0,9747908	0,9868710	0,9960240	

Komponen musiman ini digunakan untuk menangkap pola musiman berulang dalam data, dan setiap nilai komponen musiman ditempatkan sesuai urutan musimnya.

d) Rata-rata Medial

Langkah selanjutnya adalah menghitung rata-rata medial untuk setiap musim, yaitu dengan menghitung rata-rata dari nilai setiap musim sepanjang tahun. Contohnya, untuk bulan Januari, semua nilai komponen musiman pada bulan Januari dari beberapa tahun (misalnya 2019, 2020, 2021, dan 2022) dirata-ratakan, dan proses ini diterapkan juga pada bulan lainnya, dari Februari hingga Desember. Nilai rata-rata medial setiap bulan dapat dilihat pada Tabel 4:

Tabel 4. Rata-rata medial

Bulan	Rata-rata medial
Januari	0,9775340
Februari	0,9680833
Maret	0,9854726
April	1,0474047
Mei	1,0196176
Juni	0,9967639
Juli	1,0036156
Agustus	1,0040090
September	1,0060764
Oktober	1,0136217
November	1,0079085
Desember	0,9879548
Total	12,0180621

e) Indeks Musiman

Setelah mendapatkan nilai rata-rata medial, indeks musiman dihitung untuk setiap periode. Indeks musiman ini digunakan untuk menangkap pola musiman yang berulang secara teratur dalam data deret waktu dan digunakan sebagai faktor penyesuaian dalam peramalan. Untuk persamaannya dapat dilihat pada persamaan (4). Keseluruhan nilai indeks musiman dapat dilihat pada Tabel 5:

Tabel 5. Indeks musiman

Bulan	Indeks musiman
Januari	0,9760648
Februari	0,9666283
Maret	0,9839915
April	1,0458306
Mei	1,0180852
Juni	0,9952659
Juli	1,0021072
Agustus	1,0025000
September	1,0045643
Oktober	1,0120984
November	1,0063937
Desember	0,9864700

2) Komponen Trend

Langkah pertama dalam menghitung komponen trend adalah dengan menghitung *deseasonalized* data atau data yang telah dihilangkan pengaruh musiman. Untuk persamaannya dapat dilihat pada persamaan (5). Keseluruhan nilai *deseasonalized* data dapat dilihat pada Tabel 6:

Tabel 6. Deseasonalized data

Bulan	2018	2019	2020	2021	2022
Januari	13874,08	14814,59	14201,93	14215,24	14563,58
Februari	13846,07	14412,57	14237,43	14321,45	14845,42
Maret	13980,81	14426,45	14544,33	14321,52	14629,19
April	13145,53	13609,28	15677,01	13964,98	13722,11
Mei	13668,31	14032,22	14981,85	14177,79	14248,41
Juni	13989,73	14467,49	14609,88	14342,10	14613,08
Juli	14242,99	14091,31	14573,49	14570,90	14890,52
Agustus	14373,27	14129,68	14660,35	14383,74	14789,03
September	14683,98	14199,19	14533,37	14181,77	14787,50
Oktober	14723,87	14051,90	14679,40	14194,77	
November	15099,46	14036,26	14493,50	14071,03	
Desember	14555,44	14274,44	1439476	14526,54	

Setelah data deseasonalized dihitung, persamaan trend dapat digunakan untuk menghitung komponen trend. Untuk persamaannya dapat dilihat pada persamaan (6). Keseluruhan nilai dari komponen trend dapat dilihat pada Tabel 7:

Tabel 7. Komponen *trend*

Bulan	2018	2019	2020	2021	2022
Januari	14150,63	14241,54	14332,45	14423,36	14514,26
Februari	14158,21	14249,12	14340,03	14430,93	14521,84
Maret	14165,79	14256,69	14347,60	14438,51	14529,42
April	14173,36	14264,27	14355,18	14446,08	14536,99
Mei	14180,94	14271,84	14362,75	14453,66	14544,57
Juni	14188,51	14279,42	14370,33	14461,24	14552,14
Juli	14196,09	14287,00	14377,90	14468,81	14559,72
Agustus	14203,66	14294,57	14385,48	14476,39	14567,29
September	14211,24	14302,15	14393,05	14483,96	14574,87
Oktober	14218,81	14302,72	14400,63	14491,54	
November	14226,39	14317,30	14408,21	14499,11	
Desember	14233,97	14324,87	14415,78	14506,69	

3) Komponen Siklus

Komponen siklus dihitung berdasarkan nilai residual, yaitu selisih antara data aktual dengan gabungan komponen trend dan musiman. Untuk persamaannya dapat dilihat pada persamaan (7). Keseluruhan komponen musiman dapat dilihat pada Tabel 8:

Tabel 8. Residual

Bulan	2018	2019	2020	2021	2022
Januari	0,9804563	1,0402378	0,9908931	0,9855711	1,0033978
Februari	0,9779532	1,0114712	0,9928453	0,9924135	1,0222820
Maret	0,9869423	1,0119069	1,0137119	0,9918977	1,0068671
April	0,9274817	0,9540818	1,0920809	0,9666964	0,9439441
Mei	0,9638508	0,9832103	1,0431044	0,9809137	0,9796382
Juni	0,9859898	1,0131707	1,0166697	0,9917615	1,0041875
Juli	1,0033037	0,9863030	1,0136033	1,0070555	1,0227205
Agustus	1,0119408	0,9884644	1,0191074	0,9936002	1,0152212

Bulan	2018	2019	2020	2021	2022
September	1,0332651	0,9928013	1,0097485	0,9791360	1,0145891
Oktober	1,0355199	0,9819824	1,0193584	0,9795210	
November	1,0613696	0,9803705	1,0059200	0,9704755	
Desember	1,0225847	0,9964796	0,9985419	1,0013687	

Selanjutnya, nilai komponen siklus dihitung menggunakan persamaan (8). Keseluruhan nilai komponen siklus dapat dilihat pada Tabel 9:

Tabel 9. Komponen siklus

Bulan	2018	2019	2020	2021	2022
Januari		1,0247645	0,9934060	0,9921755	1,0090162
Februari	0,9817839	1,0212053	0,9991501	0,9899608	1,0108490
Maret	0,9641257	0,9924866	1,0328793	0,9836692	0,9910311
April	0,9594249	0,9830663	1,0496324	0,9798359	0,9768165
Mei	0,9591074	0,9834876	1,0506184	0,9797905	0,9759233
Juni	0,9843814	0,9942280	1,0244592	0,9932436	1,0021821
Juli	1,0004114	0,9959794	1,0164602	0,9974724	1,0140431
Agustus	1,0161699	0,9891896	1,0141531	0,9932639	1,0175103
September	1,0269086	0,9877494	1,0160714	0,9840857	
Oktober	1,0433849	0,9850514	1,0116756	0,9763775	
November	1,0398247	0,9862775	1,0079401	0,9837884	
Desember	1,0413974	0,9892477	0,9966777	0,9917473	

4) Peramalan Metode Dekomposisi Multiplikatif

Setelah ketiga komponen dihitung (musiman, *trend*, dan siklus), nilai peramalan dapat dihitung dengan mengalikan musiman *trend* dan siklus seperti pada persamaan (9). Hasil peramalan metode dekomposisi setelah dihitung dapat dilihat pada Tabel 10:

Tabel 10. Hasil peramalan metode dekomposisi multiplikatif

Bulan	2018	2019	2020	2021	2022
Januari	13811,94	14244,91	13897,15	13967,98	14294,59
Februari	13436,43	14065,67	13849,69	13809,31	14189,51
Maret	13438,96	13923,06	14582,10	13975,35	14168,60
April	14221,49	14665,39	15758,22	14803,51	14850,77
Mei	13847,02	14290,03	15362,67	14417,67	14451,09
Juni	13900,79	14129,79	14652,12	14295,53	14514,86
Juli	14231,86	14259,54	14645,36	14462,65	14795,29
Agustus	14469,42	14175,39	14625,55	14414,82	14859,43
September	14660,25	14191,42	14691,12	14318,52	14641,39
Oktober	15015,18	14266,35	14745,03	14320,39	
November	14887,53	14211,11	14615,46	14355,26	
Desember	14622,66	13979,12	14173,49	14192,31	

3.3. Metode Prophet

1) Komponen Trend

Komponen *trend* dalam prophet mengikuti perubahan jangka panjang dari deret waktu. Prophet memodelkan *trend* dengan pendekatan *piecewise linear* yang memungkinkannya menangkap perubahan trend mendadak di titik-titik tertentu yang disebut changepoints. *Trend* ini bisa meningkat, menurun,

atau tetap datar tergantung data yang ada. Untuk persamaannya dapat dilihat pada persamaan (10). Nilai komponen trend dapat dilihat pada Tabel 11.

Tabel 11. Komponen *trend*

Bulan	2018	2019	2020	2021	2022
Januari	14065,04	14222,31	14379,13	14498,47	14526,22
Februari	14078,39	14235,66	14392,41	14504,58	14523,56
Maret	14090,46	14247,71	14404,81	14509,56	14520,39
April	14103,82	14261,05	14418,06	14514,47	14516,01
Mei	14116,75	14273,95	14430,87	14518,58	14510,88
Juni	14130,10	14287,28	14441,14	14522,16	14504,64
Juli	14143,03	14300,18	14450,65	14524,94	14497,68
Agustus	14156,39	14313,50	14459,98	14527,09	14489,49
September	14169,75	14326,81	14468,83	14528,49	14480,28
Oktober	14182,67	14339,68	14476,90	14529,10	
November	14196,03	14352,98	14484,72	14528,95	
Desember	14208,95	14365,85	14491,76	14528,02	

2) Komponen Musiman

Prophet menangani komponen musiman dengan menggunakan fungsi Fourier. Komponen musiman ini digunakan untuk menangkap pola-pola yang berulang dalam jangka pendek, seperti musiman tahunan, bulanan, atau mingguan. Untuk persamaannya dapat dilihat pada persamaan (11). Nilai komponen musiman dapat dilihat pada Tabel 12:

Tabel 12. Komponen musiman

Bulan	2018	2019	2020	2021	2022
Januari	-44,41	-24,79	-8,63	1,75	4,80
Februari	-42,68	-23,25	-7,49	2,31	4,70
Maret	-41,12	-21,88	-6,47	2,76	4,56
April	-39,40	-20,38	-5,43	3,22	4,36
Mei	-37,75	-18,97	-4,46	3,60	4,11
Juni	-36,05	-17,54	-3,50	3,95	3,79
Juli	-34,42	-16,18	-2,62	4,23	3,43
Agustus	-32,75	-14,82	-1,76	4,46	3,01
September	-31,10	-13,49	-0,95	4,64	2,54
Oktober	-29,52	-12,24	-0,21	4,76	
November	-27,91	-10,98	0,50	4,83	
Desember	-26,36	-9,80	1,14	4,84	

3) Peramalan Model Prophet

Prophet menjumlahkan komponen trend dan musiman dalam model keseluruhan. Untuk persamaannya dapat dilihat pada persamaan (12). keseluruhan nilai peramalan metode prophet dapat dilihat pada Tabel 13:

Tabel 13. Hasil peramalan metode prophet

Bulan	2018	2019	2020	2021	2022
Januari	14020,63	14197,51	14370,50	14500,22	14531,02
Februari	14035,72	14212,41	14384,91	14506,89	14528,26
Maret	14049,34	14225,83	14398,34	14512,33	14524,95

Bulan	2018	2019	2020	2021	2022
April	14064,42	14240,66	14412,64	14517,69	14520,37
Mei	14079,00	14254,98	14426,42	14522,18	14514,99
Juni	14094,05	14269,75	14437,63	14526,10	14508,44
Juli	14108,61	14283,99	14448,03	14529,17	14501,11
Agustus	14123,63	14298,68	14458,22	14531,55	14492,50
September	14138,65	14313,32	14467,88	14533,13	14482,82
Oktober	14153,15	14327,45	14476,69	14533,86	
November	14168,12	14342,00	14485,23	14533,78	
Desember	14182,59	14356,04	14492,91	14532,86	

d. Evaluasi Model

Untuk mengevaluasi model, digunakan MAPE yang mengukur tingkat kesalahan peramalan. Rumus MAPE dapat dilihat pada persamaan (13). Perhitungan MAPE untuk metode dekomposisi multiplikatif dapat dilihat pada Tabel 14:

Tabel 14. Perbandingan peramalan data uji metode dekomposisi multiplikatif

Tanggal	Data Aktual	Prediksi (DM)	Error Absolut	Percentage Error (%)
2022-10-01	15303,1	15335,61	32,51	0,21
2022-11-01	15649,0	15605,25	43,75	0,28
2022-12-01	15634,5	15549,22	85,28	0,55
2023-01-01	15508,8	15371,87	136,93	0,88
2023-02-01	14990,7	15106,95	116,25	0,78
2023-03-01	15240,0	14861,37	378,63	2,48
2023-04-01	14968,6	15409,85	441,25	2,95
2023-05-01	14663,0	14853,89	190,89	1,30
2023-06-01	14984,0	14750,53	233,47	1,56
2023-07-01	15036,2	15073,76	37,56	0,25
2023-08-01	15104,0	15115,24	11,24	0,07
2023-09-01	15231,0	15245,97	14,97	0,10
2023-10-01	15487,2	15556,72	69,52	0,45
2023-11-01	15748,7	15670,57	78,13	0,50
2023-12-01	15549,3	14489,83	1059,4	6,81

Jumlah percentage error = 0,21 + 0,28 + 0,55 + 0,88 + 0,78 + 2,48 + 2,95 + 1,30 + 1,56 + 0,25 + 0,07 + 0,10 + 0,45 + 0,50 + 6,81 = 18,17

$$\text{MAPE} = \frac{18,17}{15} = 1,21\%$$

Perhitungan MAPE untuk metode prophet dapat dilihat pada Tabel 15:

Tabel 15. Perbandingan peramalan data uji metode prophet

Tanggal	Data Aktual	Prediksi (DM)	Error Absolut	Percentage Error (%)
2022-10-01	15303,1	14478,31	824,79	5,39
2022-11-01	15649,0	14473,19	1175,81	7,51
2022-12-01	15634,5	14467,79	1166,71	7,46
2023-01-01	15508,8	14461,75	1047,05	6,75
2023-02-01	14990,7	14455,23	535,47	3,57
2023-03-01	15240,0	14448,95	791,05	5,19
2023-04-01	14968,6	14441,55	527,05	3,52

Tanggal	Data Aktual	Prediksi (DM)	Error Absolut	Percentage Error (%)
2023-05-01	14663,0	14433,94	229,06	1,56
2023-06-01	14984,0	14425,62	558,38	3,73
2023-07-01	15036,2	14417,13	619,07	4,12
2023-08-01	15104,0	14407,90	696,10	4,61
2023-09-01	15231,0	14398,21	832,79	5,47
2023-10-01	15487,2	14388,39	1098,81	7,09
2023-11-01	15748,7	14377,80	1370,90	8,71
20231-2-01	15549,3	14367,11	1182,19	7,60

$$\begin{aligned} \text{Jumlah percentage error} &= 5,39 + 7,51 + 7,46 + 6,75 + 3,57 + 5,19 + 3,52 + 1,56 + 3,73 + 4,12 \\ &+ 4,61 + 5,47 + 7,09 + 8,71 + 7,60 = 81,38 \\ \text{MAPE} &= \frac{81,38}{15} = 5,43\% \end{aligned}$$

4. SIMPULAN

Berdasarkan analisis dan pembahasan sebelumnya, penelitian ini menyimpulkan bahwa metode dekomposisi multiplikatif dalam peramalan nilai tukar USD ke Rupiah menunjukkan tingkat akurasi yang sangat baik dengan nilai MAPE sebesar 1,21%. Tingkat akurasi ini berada di bawah ambang batas 10%, yang menunjukkan kemampuan prediksi yang sangat baik. Begitu pula dengan metode prophet, yang juga menunjukkan akurasi tinggi dengan nilai MAPE sebesar 5,43%, masih dalam kategori sangat baik. Namun, jika dibandingkan, metode dekomposisi multiplikatif terbukti lebih unggul dalam hal akurasi dibandingkan metode prophet dalam meramalkan nilai tukar USD ke Rupiah. Untuk penelitian selanjutnya, dapat mempertimbangkan penggunaan model atau metode lain, seperti ARIMA atau LSTM, untuk membandingkan akurasi dan kemampuan prediksi dalam meramalkan nilai tukar. Kombinasi metode atau ensemble model juga dapat dieksplorasi untuk meningkatkan akurasi ramalan. Serta pada penelitian ini memiliki batasan terkait data yang digunakan, yang terbatas pada periode tertentu. Oleh karena itu, disarankan untuk memperluas jangka waktu analisis dan mempertimbangkan faktor eksternal yang dapat mempengaruhi nilai tukar, seperti kebijakan moneter dan kondisi ekonomi global.

DAFTAR PUSTAKA

- [1] B. W. Pangesti and A. Fahrurrozi, "Prediksi nilai tukar US dollar dan ringgit Malaysia terhadap rupiah menggunakan metode long short term memory," *J. Komput. dan Teknol.*, vol. 2, no. 1, pp. 1–7, 2023, doi: <https://doi.org/10.58290/jukomtek.v2i1.82>.
- [2] D. Kartika and A. Ambya, "Pengaruh nilai tukar, investasi asing langsung, impor dan harga minyak dunia terhadap pertumbuhan ekonomi Indonesia," *BULLET : Jurnal Multidisiplin Ilmu*, vol. 1, no. 6, pp. 1277–1283, 2023, <https://journal.mediapublikasi.id/index.php/bullet/article/view/2065>.
- [3] E. Munarsih, "Peramalan jumlah pengangguran di Provinsi Sumatera Selatan dengan metode autoregressive integrated moving average (ARIMA)," *Jurnal Penelitian Sains*, vol. 19, no. 1, pp. 1–5, 2017, doi: <https://doi.org/10.56064/jps.v19i1.21>.
- [4] S. Kusumawardhani, "Implementasi association mining menggunakan algoritma dekomposisi untuk mengetahui pola tren, siklus dan faktor musiman pada perpustakaan daerah Kabupaten Sukabumi," *J. RESTIKOM: Riset Teknik Informatika dan Komputer*, vol. 2, no. 2, pp. 97–106, 2020, doi: <https://doi.org/10.52005/restikom.v2i2.70>.
- [5] B. Jange, "Prediksi harga saham Bank BCA menggunakan XGBoost," *Arbitrase: Journal of Economics and Accounting*, vol. 3, no. 2, pp. 231–237, 2022, doi: <https://doi.org/10.47065/arbitrase.v3i2.495>.

- [6] T. D. Andini and P. Auristandi, "Peramalan jumlah stok alat tulis kantor di UD Achmad Jaya menggunakan metode double exponential smoothing," *Jurnal Ilmiah Teknologi dan Informasia Asia (JITIKA)*, vol. 10, no. 1, pp. 1–10, 2016, <https://jurnal.asia.ac.id/index.php/jitika/article/view/60>.
- [7] H. D. E. Sinaga and N. Irawati, "Perbandingan Double Moving Average dengan Double Exponential Smoothing pada Peramalan Bahan Medis Habis Pakai," *J. Teknol. dan Sist. Inf.*, vol. 4, no. 2, pp. 197–204, 2018, <https://jurnal.stmikroyal.ac.id/index.php/jurteks/article/view/60>.
- [8] G. A. M. A. Putri, N. P. N. Hendayanti, and M. Nurhidayati, "Pemodelan data deret waktu dengan autoregressive integrated moving average dan logistic smoothing transition autoregressive," *J. Varian*, vol. 1, no. 1, p. 54–63, 2017, doi: <https://doi.org/10.30812/varian.v1i1.50>.
- [9] I. Christiani and N. Satyahadewi, "Peramalan produksi kelapa sawit pada PT. Perkebunan Nusantara XIII (persero) dengan metode dekomposisi," *Buletin Ilmiah Mat. Stat. dan Terapannya*, vol. 5, no. 2, pp. 119–126, 2016, doi: <https://doi.org/10.26418/bbimst.v5i02.15874>.
- [10] F. C. Kadoena, R. Rais, and L. Handayani, "Metode dekomposisi multiplikatif rata-rata bergerak untuk peramalan tingkat produksi padi ladang Sulawesi Tengah," *Nat. Sci. J. Sci. Technol.*, vol. 8, no. 2, pp. 99–105, 2019, doi: <https://doi.org/10.22487/25411969.2019.v8.i2.13533>.
- [11] N. L. E. Andjasari, N. Muhtar, L. Pimpi, L. Gubu, A. Alfian, R. Ruslan, "Komparasi antara metode dekomposisi dan winters's exponential smoothing dalam peramalan peredaran jumlah uang kartal di Indonesia," *Jurnal Matematika Komputasi dan Statistika*, vol. 4, pp. 634–644, 2024, doi: <https://doi.org/10.33772/jmks.v4i2.101>.
- [12] L. Menculini et al., "Comparing prophet and deep learning to ARIMA in forecasting wholesale food prices," *Forecasting*, vol. 3, no. 3, pp. 644–662, 2021, doi: <https://doi.org/10.3390/forecast3030040>.
- [13] M. A. Maricar, "Analisa perbandingan nilai akurasi moving average dan exponential smoothing untuk sistem peramalan pendapatan pada perusahaan XYZ," *Jurnal Sistem dan Informatika*, vol. 13, no. 2, pp. 36–45, 2019, <https://www.jsi.stikom-bali.ac.id/index.php/jsi/article/view/193>.
- [14] B. W. Pangesti and A. Fahrurrozi, "Prediksi nilai tukar US Dollar dan Ringgit Malaysia terhadap rupiah menggunakan metode long short term memory," *Jurnal Komputer dan Teknologi*, vol. 2, no. 1, pp. 1–7, 2023, doi: <https://doi.org/10.58290/jukomtek.v2i1.82>.
- [15] N. Rumondor, R. J. Kumaat, and S. Y. L. Tumangkeng, "Pengaruh nilai tukar dan jumlah uang beredar terhadap inflasi di Indonesia pada masa pandemic covid-19," *Jurnal Berkala Ilmiah Efisiensi*, vol. 21, no. 3, pp. 57–67, 2021, <https://ejournal.unsrat.ac.id/v3/index.php/jbie/article/view/36177/33>.