

KOMPARASI METODE SARIMA DAN PROPHET DALAM MERAMALKAN JUMLAH KEBERANGKATAN PENUMPANG DOMESTIK DI BANDARA NGURAH RAI

Luh Intan Chandriyani¹, I G. N. Yudi Hartawan², I Wayan Puja Astawa³

Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Pendidikan Ganesha^{1,2,3}

Corresponding e-mail: intanchandriyani@gmail.com

Copyright © 2026 The Author



This is an open access article

Creative Commons Attribution Share Alike 4.0 International Licence

DOI: [10.53866/jimi.v6i4.1581](https://doi.org/10.53866/jimi.v6i4.1581)

Received: 12 September 2026

Revised: 01 Oktober 2026

Accepted: 24 Oktober 2026

Abstrak

Tujuan – Penelitian ini bertujuan membandingkan kinerja metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan Prophet dalam meramalkan jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai.

Desain/metodologi/pendekatan – Penelitian menggunakan data bulanan keberangkatan penumpang periode Januari 2015 hingga Desember 2025 yang diperoleh dari Badan Pusat Statistik Provinsi Bali. Tahapan analisis meliputi pengujian stasioneritas, identifikasi dan estimasi model, serta evaluasi akurasi peramalan. Kinerja model diukur menggunakan *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE), dengan MAPE sebagai indikator utama. Spesifikasi Prophet menggunakan komponen tren, musiman aditif, dan regresor COVID-19.

Temuan – Prophet menghasilkan MAPE sebesar 8,93%, jauh lebih rendah dibandingkan SARIMA sebesar 26,41%. Prophet juga menghasilkan nilai MSE, RMSE, dan MAE yang lebih rendah. Temuan ini menunjukkan bahwa Prophet memiliki akurasi peramalan yang lebih baik dibandingkan model SARIMA terpilih untuk data keberangkatan penumpang yang dianalisis.

Keterbatasan penelitian/implikasi – Analisis terbatas pada data historis bulanan dari satu bandar udara. Penelitian selanjutnya perlu menguji kedua model pada beberapa bandar udara dan memasukkan variabel eksternal yang dapat memengaruhi permintaan penumpang.

Implikasi praktis – Temuan penelitian dapat membantu pengelola bandar udara dan otoritas penerbangan dalam menyusun proyeksi arus penumpang, mengalokasikan sumber daya, merencanakan kapasitas, dan mengambil keputusan operasional.

Orisinalitas/nilai – Penelitian ini memberikan bukti komparatif mengenai kinerja SARIMA dan Prophet menggunakan data penumpang yang mencakup periode sebelum, selama, dan setelah disrupsi COVID-19. Perbandingan ini mencakup spesifikasi Prophet dengan regresor COVID-19 untuk merepresentasikan periode pandemi.

Kata kunci: Peramalan, Keberangkatan Penumpang Domestik, Deret Waktu, SARIMA, Prophet

Comparison of SARIMA and Prophet Methods in Forecasting the Number of Domestic Passenger Departures at Ngurah Rai Airport

Abstract

Purpose – This study aims to compare the performance of the *Seasonal Autoregressive Integrated Moving Average* (SARIMA) and Prophet methods in forecasting domestic passenger departures at I Gusti Ngurah Rai International Airport.

Design/methodology/approach – The study used monthly passenger departure data from January 2015 to December 2025 obtained from BPS–Statistics Indonesia, Bali Province. The analysis comprised stationarity testing, model identification and estimation, and forecast accuracy evaluation. Model performance was assessed using *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), and *Mean Absolute Percentage Error* (MAPE), with MAPE as the primary evaluation criterion. The Prophet

specification incorporated trend and additive seasonality components and a COVID-19 regressor.

Findings – Prophet achieved a MAPE of 8.93%, lower than the 26.41% recorded by the selected SARIMA model on the test set. Prophet also produced lower MSE, RMSE, and MAE values. Within the scope of the selected models and the empirical test data of this study, these results indicate that Prophet yielded superior accuracy for this passenger departure series, while noting that the independent contribution of the COVID-19 regressor was not evaluated separately.

Research limitations/implications – The analysis was limited to historical monthly data from a single airport. Future studies should validate the models across multiple airports and incorporate relevant external variables that may affect passenger demand.

Practical implications – The findings can assist airport operators and aviation authorities in improving passenger-flow projections, resource allocation, capacity planning, and operational decision-making.

Originality/value – This study provides comparative evidence on SARIMA and Prophet performance using passenger data covering periods before, during, and after the COVID-19 disruption. The comparison includes a Prophet specification with a COVID-19 regressor to account for the pandemic period.

Keywords: Forecasting, domestic passenger departures, time series, SARIMA, Prophet.

1. Pendahuluan

Provinsi Bali merupakan salah satu destinasi wisata utama di Indonesia dengan tingkat kunjungan wisatawan yang tinggi ([Badan Pusat Statistik Provinsi Bali, 2023](#)). Sebagai wilayah kepulauan, Bali sangat bergantung pada transportasi udara untuk mendukung konektivitas, aktivitas pariwisata, perdagangan, serta mobilitas masyarakat. Bandar Udara Internasional I Gusti Ngurah Rai beroperasi sebagai pintu gerbang utama transportasi udara di Bali sekaligus tercatat sebagai salah satu bandara dengan aktivitas lalu lintas penerbangan tersibuk di Indonesia ([Kementerian Perhubungan Republik Indonesia, 2023](#)). Jumlah keberangkatan penumpang domestik pada bandara ini cenderung berfluktuasi dari waktu ke waktu, yang antara lain berasosiasi dengan faktor musiman seperti periode liburan sekolah, hari raya keagamaan, serta dinamika kondisi ekonomi ([Durrach et al., 2018](#); [Ridla et al., 2023](#)). Selain itu, terjadinya pandemi COVID-19 turut memberikan tekanan dan perubahan signifikan terhadap pola pergerakan penumpang penerbangan domestik ([Nur Aziza et al., 2023](#)).

Perubahan jumlah penumpang yang bersifat dinamis menyebabkan kebutuhan akan peramalan yang akurat menjadi semakin penting. Informasi hasil peramalan dapat digunakan sebagai dasar dalam perencanaan operasional bandara, pengelolaan fasilitas, serta alokasi sumber daya secara lebih efektif. Oleh karena itu, diperlukan metode peramalan yang mampu menangkap pola data historis sehingga dapat menghasilkan prediksi yang akurat.

Dalam analisis deret waktu (*time series*), metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan Prophet merupakan dua metode yang banyak digunakan. SARIMA merupakan pengembangan dari ARIMA yang mampu mengakomodasi pola musiman dalam data ([Cryer & Chan, 2008](#)), sedangkan Prophet merupakan metode berbasis model aditif yang dapat memodelkan tren dan musiman secara fleksibel ([Taylor & Letham, 2018](#)). Kedua metode tersebut memiliki karakteristik yang berbeda dalam menangani pola data deret waktu sehingga menarik untuk dibandingkan pada data keberangkatan penumpang domestik.

Beberapa penelitian sebelumnya telah menerapkan metode SARIMA dan Prophet pada data transportasi udara. [Nur Aziza et al. \(2023\)](#) membandingkan metode SARIMA intervensi dan Prophet pada data jumlah penumpang Bandara Soekarno–Hatta dan memperoleh nilai MAPE sebesar 28% untuk SARIMA intervensi serta 37% untuk Prophet. Sementara itu, [Durrach et al. \(2018\)](#) menggunakan metode SARIMA untuk meramalkan jumlah penumpang di Bandara Sultan Iskandar Muda dan menghasilkan nilai MAPE sebesar 9,79%. Penelitian lain yang dilakukan oleh [Rahmawati \(2024\)](#) menggunakan metode Prophet untuk meramalkan jumlah penumpang pesawat Citilink selama masa pandemi dengan nilai MAPE sebesar 25,31%. Namun, sebagian besar penelitian tersebut hanya berfokus pada satu metode atau menggunakan objek penelitian yang berbeda sehingga belum memberikan gambaran yang jelas mengenai kinerja relatif SARIMA dan Prophet pada data keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai.

Berdasarkan kondisi tersebut, penelitian ini bertujuan membandingkan kinerja metode SARIMA dan Prophet dalam memprediksi jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai. Perbandingan dilakukan menggunakan metrik *Mean Squared Error* (MSE), *Root Mean Squared*

Error (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian diharapkan dapat memberikan informasi mengenai metode yang memiliki tingkat akurasi terbaik serta menjadi bahan pertimbangan dalam mendukung perencanaan operasional bandara.

2. Metode Penelitian

2.1. *Objek Waktu dan Tempat Penelitian*


Objek penelitian ini adalah jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai. Data penelitian berupa data sekunder bulanan periode Januari 2015 hingga Desember 2025 yang diperoleh dari situs web resmi Badan Pusat Statistik (BPS), merujuk pada Tabel Statistik Jumlah Penumpang Pesawat (Angkutan Udara) Domestik di 5 Bandara Utama ([Badan Pusat Statistik Bali, 2026](#)) serta dikompilasi dengan publikasi berkala BPS Provinsi Bali [Statistik Transportasi Udara dan Laut Provinsi Bali](#).

2.2. *Teknik Pengumpulan Data*

Teknik pengumpulan data dilakukan melalui metode dokumentasi dan studi literatur. Data sekunder berupa jumlah keberangkatan penumpang domestik periode Januari 2015–Desember 2025 diperoleh dari situs web resmi Badan Pusat Statistik (BPS) Provinsi Bali. Studi literatur digunakan untuk memperoleh referensi yang mendukung penerapan metode SARIMA, Prophet, dan evaluasi akurasi peramalan.

2.3. *Teknik Analisis Data*

Penelitian ini menggunakan pendekatan kuantitatif dengan jenis penelitian terapan (*applied research*) yang berfokus pada peramalan jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai. Data yang digunakan merupakan data sekunder berupa jumlah keberangkatan penumpang domestik bulanan periode Januari 2015 hingga Desember 2025 yang diperoleh dari Badan Pusat Statistik (BPS) Provinsi Bali. Pengolahan dan analisis data dilakukan menggunakan bahasa pemrograman Python dengan menerapkan metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan Prophet. Kedua metode tersebut dibandingkan berdasarkan nilai Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE) untuk mengetahui metode yang menghasilkan tingkat kesalahan peramalan lebih rendah. Tahapan penelitian disajikan dalam bentuk diagram alir sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alir Teknik Analisis Data

2.3.1 Proses Analisis Data

Data jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai periode 2015–2025 diperoleh dari Badan Pusat Statistik (BPS). Data tersebut dianalisis untuk mengidentifikasi pola pergerakan penumpang dan dibagi menjadi data latih (*training data*) untuk membangun model serta data uji

(*testing data*) untuk mengevaluasi akurasi peramalan menggunakan metode SARIMA dan Prophet.

Tabel 1. Data Jumlah Keberangkatan Penumpang

Jumlah Keberangkatan Penumpang Tahun 2015–2025 pada Penerbangan Domestik Bandara I Gusti Ngurah Rai	
Tahun	Jumlah
2015	4.122.180
2016	4.925.589
2017	5.101.402
2018	5.577.535
2019	4.955.803
2020	1.775.528
2021	1.780.979
2022	3.878.209
2023	4.721.260
2024	4.719.048
2025	4.335.171

Dalam proses analisis, data dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji (*testing data*). Data latih digunakan untuk membangun model peramalan, sedangkan data uji digunakan untuk mengukur akurasi hasil prediksi dari masing-masing metode.

Tabel 2. Pembagian Data Latih dan Data Uji

Bagian Data	Periode	Jumlah Observasi	Kegunaan
Data Latih	Januari 2015–September 2023	105	Estimasi/Pembentukan Model
Data Uji	Oktober 2023–Desember 2025	27	Evaluasi Hasil Ramalan
Keseluruhan	Januari 2015–Desember 2025	132	Sumber Data Penelitian

2.3.2 Pemodelan dengan Metode SARIMA

Selanjutnya, analisis dilakukan menggunakan metode SARIMA. Tahapan yang dilakukan meliputi pengujian stasioneritas data menggunakan uji Augmented Dickey–Fuller (ADF), proses *differencing* apabila data belum stasioner, identifikasi parameter model melalui analisis *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), estimasi parameter model, serta diagnostik model untuk memperoleh model SARIMA terbaik. Kandidat model dievaluasi menggunakan Akaike Information Criterion (AIC) dan Bayesian Information Criterion (BIC), dengan AIC sebagai dasar utama pemilihan model (Cryer & Chan, 2008).

Persamaan uji ADF

$$\Delta Y_t = \alpha + \beta t + \gamma Y_{t-1} + \delta_1 \Delta Y_{t-1} + \delta_2 \Delta Y_{t-2} + \dots + \epsilon_t$$

Keterangan

ΔY_t = Selisih nilai deret waktu, yaitu $y_t - y_{t-1}$.

α = Konstanta atau intersep.

βt = Komponen tren waktu linear yang disertakan apabila diperlukan.

γ = Koefisien untuk pengujian akar unit; $\gamma = 0 \rightarrow$ deret waktu mengandung akar unit di bawah hipotesis nol.

Y_{t-1} = Nilai deret waktu pada bulan sebelumnya, yang dikalikan dengan koefisien γ .

$\delta_1 \Delta Y_{t-1}, \delta_2 \Delta Y_{t-2}, \dots$ = Komponen selisih tertunda dari periode-periode sebelumnya.

ϵ_t = Galat acak.

Dalam bentuk hipotesis menjadi:

$H_0: \rho = 1$, yaitu deret waktu mengandung akar unit.

$H_a: \rho < 1$, yaitu deret waktu tidak mengandung akar unit.

Keputusan statistik diambil berdasarkan nilai- p (p -value) dari statistik uji ADF dengan tingkat signifikansi $\alpha = 0,05$. Jika nilai- p lebih kecil dari 0,05, maka hipotesis nol (H_0) ditolak, yang mengindikasikan bahwa deret waktu bersifat stasioner. Sebaliknya, jika nilai- p sama dengan atau lebih besar dari 0,05, terdapat cukup bukti untuk gagal menolak hipotesis nol (H_0), sehingga proses pembedaan (*differencing*) perlu dipertimbangkan untuk menstasionerkan data sebelum dilakukan pemodelan SARIMA.

Identifikasi parameter model menggunakan plot ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*) memainkan peran sentral dalam tahap identifikasi model *deret waktu*, khususnya dalam model SARIMA. Plot ACF memberikan informasi tentang keterkaitan antara nilai-nilai masa lalu dan nilai saat ini dalam sebuah deret waktu. Setiap titik pada plot ACF menunjukkan koefisien autokorelasi untuk suatu *lag* tertentu, yang memberikan gambaran mengenai pola keterkaitan dalam data. Jika nilai autokorelasi tinggi secara signifikan pada *lag* tertentu, hal ini menunjukkan adanya pola berulang atau hubungan jangka panjang yang dapat dimanfaatkan dalam pemodelan. Sebaliknya, plot PACF menunjukkan korelasi parsial, yaitu korelasi antara nilai saat ini dan nilai masa lalu pada *lag* tertentu dengan mengontrol (menghilangkan) pengaruh semua *lag* di antara keduanya.

Persamaan ACF

$$\rho_k = \frac{\sum_{t=k+1}^T (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^T (Y_t - \bar{Y})^2}$$

Keterangan

ρ_k = Koefisien ACF pada lag ke- k .

T = Jumlah observasi.

$\bar{Y}$ = Rata-rata deret waktu.

Sebagai contoh, $\rho_1 = 0,5$ menunjukkan korelasi positif sebesar 0,5 antara nilai bulan ini dan nilai bulan sebelumnya. Pola ACF membantu mengidentifikasi orde MA(q) ketika autokorelasi terputus setelah lag ke- q , sedangkan penurunan yang lambat dapat mengindikasikan ketidakstasioneran.

Persamaan PACF

$$\phi_{kk} = \text{Corr}(Y_t - \hat{Y}_t^*, Y_{t-k} - \hat{Y}_{t-k}^*)$$

Keterangan

ϕ_{kk} = Koefisien PACF pada lag ke- k setelah pengaruh lag di antaranya dikendalikan.

$\hat{Y}_t$ = Prediksi $\hat{Y}_t$ berdasarkan $Y_{t-1}, \dots, Y_{t-k+1}$.

PACF digunakan untuk mengidentifikasi orde AR(p). Jika PACF terputus setelah lag ke- p , pola tersebut mengindikasikan kandidat komponen AR(p). Sebagai contoh, PACF yang signifikan hanya pada lag pertama mengindikasikan kandidat AR(1), sedangkan signifikansi hingga lag ke- p mengindikasikan kandidat AR(p).

2.3.3 Pemodelan dengan Metode Prophet

Selain menggunakan SARIMA, analisis juga dilakukan menggunakan metode Prophet. Pada tahap ini, data disesuaikan dengan struktur masukan Prophet yang terdiri atas kolom waktu (ds) dan kolom target (y). Selanjutnya ditambahkan *regresor* COVID-19 untuk merepresentasikan periode yang terdampak pandemi sehingga model dapat mempertimbangkan perubahan pola data yang terjadi selama masa pandemi. Model Prophet kemudian dilatih menggunakan data latih untuk mempelajari pola tren, pola musiman, serta pengaruh *regresor* terhadap jumlah keberangkatan penumpang domestik.

Setelah data dipersiapkan, model Prophet ditetapkan menggunakan beberapa parameter untuk mengatur sensitivitas dan fleksibilitasnya (Taylor & Letham, 2018). Parameter yang digunakan adalah sebagai berikut.

Keterangan

changepoint_prior_scale = 0.01 (mengatur fleksibilitas model dalam menangkap perubahan tren).

$yearly_seasonality = True$ (mengaktifkan komponen musiman tahunan).

$seasonality_prior_scale = 0.1$ (mengatur regularisasi komponen musiman).

$holidays_prior_scale = 1$ (mengatur regularisasi efek hari libur apabila komponen tersebut disertakan).

Selain dilakukan penyesuaian parameter model, variabel regresor eksternal COVID-19 turut diikutsertakan dalam pemodelan Prophet untuk mengakomodasi anomali pola data pada periode pandemi. Model kemudian dilatih menggunakan data latih sebanyak 105 observasi (atau sekitar 80% dari total keseluruhan 132 data historis bulanan periode Januari 2015 hingga September 2023), sedangkan sisa 27 observasi (20% data berikutnya dari Oktober 2023 hingga Desember 2025) dialokasikan sebagai data uji (*testing data*). Konsistensi pembagian data ini diterapkan secara seragam pada pemodelan SARIMA maupun Prophet.

Untuk merepresentasikan dampak pandemi, model Prophet dilengkapi dengan variabel penjelas tambahan (*external regressor*) berupa `covid_impact`. Variabel biner ini didefinisikan dengan nilai 1 untuk periode berlangsungnya pembatasan pandemi COVID-19 (Maret 2020 hingga Desember 2021) dan nilai 0 untuk periode di luar rentang tersebut, yang ditetapkan berdasarkan laporan resmi mobilitas transportasi udara BPS. Pada horizon peramalan masa depan (periode 2026–2027), nilai regressor diset menjadi 0 karena kondisi operasional penerbangan diasumsikan telah kembali normal. Interval ketidakpastian (*uncertainty interval*) dihasilkan melalui batas bawah (`yhat_lower`) dan batas atas (`yhat_upper`) berdasarkan simulasi posterior dari komponen tren dan musiman model Prophet.

2.3.4 Metrik Evaluasi Akurasi

Setelah diperoleh model terbaik dari masing-masing metode, dilakukan proses peramalan pada data uji. Hasil peramalan kemudian dibandingkan dengan data aktual untuk mengetahui tingkat akurasi model. Evaluasi dilakukan menggunakan empat metrik, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). MSE digunakan untuk mengukur rata-rata kuadrat kesalahan prediksi, RMSE digunakan untuk mengetahui besarnya kesalahan prediksi dalam satuan asli data, MAE digunakan untuk menghitung rata-rata kesalahan absolut, sedangkan MAPE digunakan untuk mengukur tingkat kesalahan dalam bentuk persentase.

Rumus *Mean Squared Error* (MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

Keterangan

n = Banyaknya data/observasi yang dievaluasi.

$\sum$ = Operator penjumlahan untuk seluruh observasi dari $t = 1$ hingga n .

y_t = Nilai aktual pada periode ke- t ($t = 1, \dots, n$).

$\hat{y}_t$ = Nilai hasil peramalan (prediksi) pada periode ke- t ($t = 1, \dots, n$).

$(y_t - \hat{y}_t)^2$ = Kuadrat selisih antara nilai aktual dan nilai prediksi.

MSE memberikan indikasi seberapa baik model memprediksi nilai aktual, dan semakin rendah nilai MSE, semakin baik pula performa model dalam melakukan prediksi.

Rumus *Root Mean Squared Error* (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

Keterangan

MSE = Mean Squared Error

$\sqrt{}$ = Fungsi akar kuadrat

RMSE menyatakan besarnya kesalahan peramalan dalam satuan yang sama dengan data aktual. Nilainya selalu tidak negatif; nilai yang lebih kecil menunjukkan kesalahan peramalan yang lebih rendah pada data evaluasi yang sama.

Rumus *Mean Absolute Error* (MAE)

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

Keterangan

$F(X_i)$ = Nilai prediksi pada periode ke- t ($t = 1, \dots, n$)

y_i = Nilai aktual pada periode ke- t ($t = 1, \dots, n$)

n = Banyaknya data yang diuji

Σ = Operator penjumlahan untuk seluruh observasi yang dievaluasi

$\frac{1}{n}$ = Faktor pembagi untuk memperoleh rata-rata kesalahan absolut

MAE memberikan ukuran rata-rata dari kesalahan prediksi dalam skala yang sama dengan variabel yang diamati, dan semakin rendah nilai MAE, semakin baik modelnya dalam melakukan prediksi.

Rumus *Mean Absolute Percentage Error* (MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\%$$

Keterangan

n = Banyaknya data/observasi yang dievaluasi.

$\sum_{t=1}^n$ = Operator penjumlahan dari periode pertama ($t = 1$) hingga periode ke- n .

y_t = Nilai aktual pada periode ke- t ($t = 1, \dots, n$).

$\hat{y}_t$ = Nilai hasil peramalan (prediksi) pada periode ke- t ($t = 1, \dots, n$).

$\left| \frac{y_t - \hat{y}_t}{y_t} \right|$ = Persentase selisih absolut relatif terhadap nilai aktual pada periode ke- t .

MAPE menyatakan rata-rata kesalahan absolut relatif terhadap nilai aktual dalam bentuk persentase (Nuha, 2023). Interpretasinya perlu mempertimbangkan besarnya nilai aktual karena MAPE tidak terdefinisi ketika nilai aktual sama dengan nol dan dapat menjadi sangat besar ketika nilai aktual mendekati nol.

Dalam penelitian ini, nilai MAPE digunakan sebagai indikator utama untuk menentukan model terbaik karena mampu menunjukkan tingkat kesalahan prediksi secara relatif terhadap nilai aktual dan lebih mudah diinterpretasikan dalam bentuk persentase. Model yang menghasilkan nilai MAPE paling rendah dianggap memiliki tingkat akurasi yang lebih baik.

3. Hasil dan Pembahasan

3.1. Hasil Penelitian

Secara keseluruhan, data jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai menunjukkan adanya pola musiman yang relatif konsisten dari tahun ke tahun. Hal ini dapat diamati dari peningkatan jumlah penumpang yang terjadi pada bulan-bulan tertentu, khususnya yang bertepatan dengan periode liburan, seperti masa liburan sekolah, hari raya keagamaan (misalnya Idul Fitri dan Natal), serta hari besar dan cuti bersama. Lonjakan jumlah penumpang pada periode-periode tersebut mencerminkan pola perjalanan musiman yang umum terjadi di Indonesia, ketika masyarakat cenderung melakukan perjalanan udara domestik dalam jumlah besar pada waktu-waktu tertentu setiap tahun.



Gambar 2. Grafik Jumlah Keberangkatan Penumpang Domestik Tahun 2015–2025

Sebelum 2020, jumlah keberangkatan penumpang berkisar antara 300.000 dan lebih dari 500.000 orang per bulan. Grafik menunjukkan penurunan tajam hingga mendekati nol pada 2020, bertepatan dengan pandemi COVID-19. Setelah itu, jumlah penumpang mulai pulih secara bertahap sejak 2021 dan kembali berfluktuasi pada kisaran 300.000–450.000 orang per bulan selama 2023–2025.



Gambar 3. Dekomposisi Musiman Jumlah Keberangkatan Penumpang Domestik Tahun 2015–2025

Hasil dekomposisi aditif menunjukkan adanya pola musiman tahunan yang konsisten dengan fluktuasi berulang antara -40.000 hingga 40.000 penumpang. Sementara itu, komponen residual menunjukkan anomali ekstrem (di bawah -150.000) pada 2020–2021 sebelum akhirnya kembali stabil di sekitar garis nol sejak 2022. Pola tersebut mengindikasikan kemungkinan ketidakstasioneran yang selanjutnya diperiksa menggunakan uji ADF.

3.1.1 Hasil Penelitian Pemodelan SARIMA

Sebelum tahap pemodelan SARIMA, data jumlah keberangkatan penumpang domestik yang telah melalui prapemrosesan diuji kestasionerannya menggunakan metode *Augmented Dickey-Fuller* (ADF) untuk menentukan apakah data memerlukan proses *differencing*.

```

result_original = adfuller(df["Total"])

print(result_original)
print(f"ADF Statistic (Original): {result_original[0]:.4f}")
print(f"p-value (Original): {result_original[1]:.4f}")

if result_original[1] < 0.05:
    print("Data original bersifat stasioner.\n")
else:
    print("Data original bersifat non-stasioner.\n")

df["Total_diff"] = df["Total"].diff()

result_diff = adfuller(df["Total_diff"].dropna())

print(result_diff)
print(f"ADF Statistic (Differencing): {result_diff[0]:.4f}")
print(f"p-value (Differencing): {result_diff[1]:.4f}")
if result_diff[1] < 0.05:
    print("Data yang sudah Differencing sudah Stasioner.")
else:
    print("Data yang sudah Differencing belum Stasioner.")

```

Gambar 4. Kode Uji Stasioneritas dengan ADF

Pengujian pertama dilakukan pada data asli (tanpa diferensiasi). Nilai statistik uji ADF awal yang diperoleh adalah sebesar $-1,8990$ dengan nilai- p (p -value) sebesar $0,3325$. Hal ini menunjukkan bahwa hipotesis nol (H_0) adanya akar unit tidak dapat ditolak pada taraf signifikansi $\alpha = 5\%$. Setelah dilakukan pembedaan pertama (*differencing* orde 1), nilai statistik ADF menjadi $-3,1682$ dengan nilai- p sebesar $0,0219$, sehingga hipotesis nol ditolak. Hasil ini mendukung penggunaan data hasil *differencing* untuk tahap identifikasi model selanjutnya.

Tabel 3. Hasil Uji Stasioneritas ADF

Kondisi	ADF Statistic	p - value	Kesimpulan
Awal	-1,8990	0,3325	Non-stasioner
Differencing 1x	-3,1682	0,0219	Stasioner

```

fig, axes = plt.subplots(1, 2, figsize=(16, 4))

plot_acf(df['Total_diff'].dropna(), lags=40, ax=axes[0])
axes[0].set_title('Autocorrelation Function (ACF)')


plot_pacf(df['Total_diff'].dropna(), lags=40, ax=axes[1])
axes[1].set_title('Partial Autocorrelation Function (PACF)')

plt.tight_layout()
plt.show()

```

Gambar 5. Kode ACF dan PACF

Grafik Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) disajikan secara berdampingan hingga 40 lag. ACF menunjukkan korelasi antara nilai pada suatu periode dan nilai pada periode sebelumnya pada berbagai lag, sedangkan PACF menunjukkan korelasi parsial setelah pengaruh lag di antaranya dikendalikan.



Gambar 6. Plot ACF dan PACF dari Data yang Sudah Stasioner


Pola ACF dan PACF setelah differencing digunakan untuk menentukan kandidat model SARIMA. Kandidat tersebut kemudian dievaluasi menggunakan AIC dan BIC. Kedua kriteria menyeimbangkan kecocokan model dan kompleksitasnya, dengan nilai yang lebih kecil lebih disukai. Dalam penelitian ini, model akhir dipilih berdasarkan AIC terkecil, sedangkan BIC digunakan sebagai pertimbangan tambahan.

Tabel 4. Nilai AIC dan BIC Kandidat Model SARIMA dengan $s = 12$

Urutan	Kombinasi	AIC	BIC
1	(1, 1, 1) (1, 1, 1, 12)	2314.05	2326.66
2	(1, 1, 1) (0, 1, 2, 12)	2314.17	2326.78
3	(1, 1, 1) (0, 1, 1, 12)	2314.62	2324.71
...	...	...	...
4	(0, 1, 2)(0, 1, 0, 12)	2334.50	2342.06
5	(0, 1, 0)(0, 1, 0, 12)	2336.33	2338.85

Dari kombinasi parameter yang diuji, model SARIMA (1,1,1)(1,1,1)₁₂ menghasilkan AIC terkecil, yaitu 2.314,05, dengan BIC sebesar 2.326,66. Meskipun nilai BIC model ini bukan yang terkecil, model dipilih berdasarkan AIC sebagai kriteria utama. Akurasi peramalan model terpilih selanjutnya dievaluasi menggunakan data uji.

Model SARIMA dilatih menggunakan data latih dengan differencing nonmusiman $d = 1$, differencing musiman $D = 1$, dan periode musiman $s = 12$ bulan. Model ini mencakup komponen autoregresif (AR), moving average (MA), autoregresif musiman (SAR), dan moving average musiman (SMA).




Gambar 7. Hasil Peramalan Metode SARIMA (1,1,1)(1,1,1)₁₂

Model tersebut kemudian digunakan untuk menghasilkan peramalan pada data uji dan dievaluasi tingkat akurasinya.

3.1.2 Hasil Penelitian Pemodelan Prophet

Selain menggunakan SARIMA, penelitian ini juga menerapkan metode Prophet. Model Prophet dibangun menggunakan komponen tren, musiman, dan *regresor* COVID-19 untuk mempertimbangkan perubahan pola data yang terjadi selama pandemi.

Setelah proses pelatihan model menggunakan data latih, Prophet digunakan untuk menghasilkan peramalan pada data uji. Hasil peramalan menunjukkan bahwa model mampu mengikuti tren pemulihan jumlah penumpang dan tetap menangkap pola musiman tahunan yang terdapat pada data.




Gambar 8. Hasil Peramalan Prophet

3.1.3 Evaluasi dan Perbandingan Akurasi Kedua Metode

Setelah diperoleh hasil peramalan dari kedua metode, dilakukan evaluasi akurasi menggunakan metrik MSE, RMSE, MAE, dan MAPE. Nilai yang lebih kecil menunjukkan tingkat kesalahan prediksi yang lebih rendah dan akurasi yang lebih baik.

Tabel 5. Perbandingan Akurasi Peramalan SARIMA dan Prophet

Metode	MSE	RMSE	MAE	MAPE
SARIMA	11873110158.7466	108963.8021	92468.4982	26.41%
Prophet	1539137758.6055	39231.8462	31167.0078	8.93%



Gambar 9. Komparasi Hasil Peramalan SARIMA dan Prophet

Berdasarkan hasil evaluasi pada Tabel 5 dan Gambar 9, metode Prophet menghasilkan nilai kesalahan yang lebih rendah dibandingkan SARIMA pada seluruh metrik evaluasi, yaitu MSE, RMSE, MAE, dan MAPE. Selanjutnya, nilai MAPE digunakan untuk menentukan kategori akurasi prediksi berdasarkan rentang

nilai yang disajikan pada Tabel 6.


Tabel 6. Rentang Nilai MAPE dan Kategori Akurasi Peramalan (Lewis, 1982)

No	Rentang Nilai	Akurasi Prediksi
1	$MAPE < 10\%$	Sangat Baik (<i>Highly Accurate</i>)
2	$10\% \leq MAPE < 20\%$	Baik (<i>Good Forecast</i>)
3	$20\% \leq MAPE \leq 50\%$	Cukup (<i>Reasonable Forecast</i>)
4	$MAPE > 50\%$	Buruk (<i>Inaccurate Forecast</i>)

Berdasarkan hasil evaluasi pada Tabel 5 dan Gambar 9, metode Prophet menghasilkan nilai kesalahan yang lebih rendah dibandingkan SARIMA pada seluruh metrik evaluasi (MSE, RMSE, MAE, dan MAPE). Selanjutnya, nilai MAPE digunakan untuk menentukan kategori interpretasi akurasi prediksi berdasarkan rentang rujukan standar yang disajikan pada Tabel 6 (Lewis, 1982).


Pada data uji, model Prophet menghasilkan nilai MSE sebesar 1.539.137.758,61 (atau 1.539.137.758,6055), RMSE sebesar 39.231,85 (atau 39.231,8462), MAE sebesar 31.167,01, dan MAPE sebesar 8,93%. Sementara itu, model SARIMA menghasilkan nilai MSE sebesar 11.873.110.158,75 (atau 11.873.110.158,7466), RMSE sebesar 108.963,80 (atau 108.963,8021), MAE sebesar 92.468,50 (atau 92.468,4982), dan MAPE sebesar 26,41%. Berdasarkan kriteria interpretasi pada Tabel 6, nilai MAPE model Prophet (8,93%) termasuk dalam kategori sangat baik ($MAPE < 10\%$), sedangkan model SARIMA (26,41%) berada pada kategori cukup ($20\% \leq MAPE \leq 50\%$). Perbandingan ini menunjukkan bahwa model Prophet menghasilkan tingkat presisi peramalan yang lebih tinggi serta kesalahan yang lebih rendah pada data uji penelitian ini.

Setelah diperoleh model dengan tingkat akurasi yang baik, dilakukan peramalan untuk periode selanjutnya menggunakan seluruh data historis sebagai data latih. Hasil peramalan digunakan untuk memproyeksikan tren jumlah keberangkatan penumpang pada periode mendatang.



Gambar 10. Hasil Peramalan SARIMA untuk Satu Tahun ke Depan

Berdasarkan grafik hasil peramalan, model SARIMA menunjukkan pola musiman yang jelas dengan jumlah penumpang yang berfluktuasi sepanjang tahun. Prediksi meningkat pada awal dan pertengahan tahun, menurun pada beberapa periode tertentu, kemudian kembali meningkat menjelang akhir tahun yang dapat berkaitan dengan pola perjalanan pada musim liburan. Hasil ini menunjukkan bahwa SARIMA mampu menangkap pola musiman tahunan sehingga dapat digunakan sebagai dasar perencanaan operasional dan transportasi udara pada periode mendatang.



Gambar 11. Hasil Peramalan Prophet untuk Satu Tahun ke Depan

Berdasarkan grafik hasil peramalan, model Prophet mampu menangkap pola musiman dan tren jangka panjang jumlah penumpang di Bandara I Gusti Ngurah Rai dengan baik. Jumlah penumpang diprediksi meningkat secara bertahap hingga pertengahan tahun, kemudian menurun pada Agustus–September sebelum kembali meningkat akhir tahun yang dapat berkaitan dengan pola perjalanan pada musim liburan. Hasil peramalan menunjukkan pola yang lebih halus dengan tren yang cenderung meningkat, namun tetap mampu merepresentasikan fluktuasi musiman tahunan. Oleh karena itu, model Prophet dapat digunakan sebagai dasar perencanaan strategis bandara dan transportasi udara pada periode mendatang.

3.2. Pembahasan

Hasil penelitian menunjukkan bahwa metode Prophet memiliki tingkat akurasi yang lebih baik dibandingkan metode SARIMA dalam memprediksi jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai. Hal ini ditunjukkan oleh nilai MSE, RMSE, MAE, dan MAPE yang lebih rendah dibandingkan SARIMA. Berdasarkan indikator utama yang digunakan dalam penelitian ini, yaitu MAPE, Prophet memperoleh nilai sebesar 8,93%, sedangkan SARIMA memperoleh nilai sebesar 26,41%. Hasil tersebut menunjukkan bahwa Prophet mampu menghasilkan prediksi yang lebih mendekati nilai aktual.

Kinerja Prophet yang lebih baik diduga berkaitan dengan fleksibilitas komponen tren dan musimannya serta penggunaan regresor COVID-19. Data penelitian menunjukkan penurunan tajam selama pandemi dan peningkatan pada masa pemulihan. Namun, kontribusi masing-masing komponen terhadap akurasi belum diuji secara terpisah sehingga keunggulan model belum dapat secara khusus diatribusikan kepada regresor COVID-19.

Hasil penelitian ini berbeda dengan penelitian [Nur Aziza et al. \(2023\)](#) yang menemukan bahwa SARIMA intervensi lebih unggul dibandingkan Prophet dalam memprediksi jumlah penumpang di Bandara Internasional Soekarno-Hatta. Perbedaan hasil tersebut menunjukkan bahwa performa metode peramalan sangat dipengaruhi oleh karakteristik data yang digunakan. Di sisi lain, hasil penelitian ini mendukung temuan [Rahmawati \(2024\)](#) yang menunjukkan bahwa Prophet mampu menangkap pola tren dan musiman pada data transportasi udara, serta sejalan dengan penelitian [Durratun et al. \(2018\)](#) yang melaporkan penerapan SARIMA untuk meramalkan jumlah penumpang di Bandara Sultan Iskandar Muda.

3.3. Kaitan dengan Tujuan Penelitian

Penelitian ini bertujuan untuk membandingkan tingkat akurasi metode SARIMA dan Prophet dalam memprediksi jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai. Berdasarkan hasil evaluasi menggunakan MSE, RMSE, MAE, dan MAPE, tujuan tersebut telah tercapai melalui identifikasi model terbaik dari masing-masing metode serta perbandingan kinerja peramalannya.

Temuan penelitian menunjukkan bahwa model SARIMA terbaik yang diperoleh adalah SARIMA (1,1,1)(1,1,1)₁₂, sedangkan model Prophet terbaik dibangun menggunakan komponen tren, musiman, dan regresor COVID-19. Hasil evaluasi menunjukkan bahwa Prophet menghasilkan nilai MAPE sebesar 8,93%,

lebih rendah dibandingkan SARIMA sebesar 26,41%, sehingga Prophet menjadi metode dengan tingkat akurasi terbaik pada penelitian ini.

Selain menjawab tujuan penelitian, hasil yang diperoleh juga mengisi kesenjangan penelitian yang telah diidentifikasi sebelumnya. Beberapa penelitian terdahulu umumnya hanya menerapkan salah satu metode atau menghasilkan temuan yang berbeda pada objek penelitian yang berbeda. Oleh karena itu, penelitian ini memberikan bukti empiris mengenai kinerja SARIMA dan Prophet pada data keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai. Hasil penelitian menunjukkan bahwa pada data yang mengalami perubahan pola akibat pandemi dan masa pemulihan, spesifikasi Prophet yang diuji menghasilkan kesalahan peramalan yang lebih rendah dibandingkan model SARIMA terpilih.

4. Kesimpulan

Penelitian ini berhasil membandingkan kinerja metode SARIMA dan Prophet dalam memprediksi jumlah keberangkatan penumpang domestik di Bandara Internasional I Gusti Ngurah Rai menggunakan data bulanan periode Januari 2015–Desember 2025. Hasil analisis menunjukkan bahwa model terbaik yang diperoleh untuk metode SARIMA adalah SARIMA (1,1,1)(1,1,1)₁₂, sedangkan model Prophet dibangun menggunakan komponen tren, musiman, dan *regresor* COVID-19. Berdasarkan evaluasi menggunakan MSE, RMSE, MAE, dan terutama MAPE sebagai indikator utama akurasi, metode Prophet menghasilkan kinerja yang lebih baik dibandingkan SARIMA dengan nilai MAPE sebesar 8,93%, sedangkan SARIMA sebesar 26,41%. Temuan ini mendukung penggunaan Prophet sebagai alternatif untuk membantu perencanaan dan pengambilan keputusan operasional pada konteks data yang diteliti.

Pernyataan Pengungkapan AI

Para penulis menyatakan menggunakan kecerdasan buatan (AI) seperti ChatGPT Pro dan Gemini Pro. Penulis menggunakan AI untuk membantuk parafrase kalimat dan meningkatkan keterbacaan bahasa naskah antara lain penyuntingan tata bahasa, ejaan, dan kejelasan kalimat. Penggunaan kecerdasan buatan tidak untuk digunakan menghasilkan ide penelitian, metodologi, analisis data, menafsirkan hasil, referensi dan menarik kesimpulan. Semua konten yang dibantu oleh kecerdasan buatan telah ditinjau dan di verifikasi oleh seluruh para penulis.

Pernyataan Ketersediaan Data

Naskah dan materi suplemen memuat data empiris yang mendukung hasil penelitian ini. Sementara itu, data mentah atau dataset yang lebih rinci terkait topik ini tersedia dari penulis korespondensi apabila diminta untuk kepentingan akademik yang dapat dipertanggungjawabkan.

Konflik Kepentingan

Para penulis menyatakan tidak ada konflik kepentingan terkait dengan penelitian ini.

Ucapan Terimakasih

Para penulis mengucapkan terima kasih kepada para peserta atas kontribusi berharga mereka

Pendanaan

Penelitian ini didanai sendiri oleh para penulis. Tidak ada dukungan atau bantuan eksternal yang diterima.

Bibliografi

- Angkasa Pura I. (2020). *Laporan tahunan PT Angkasa Pura I*. PT Angkasa Pura I.
- Aswi, & Sukarna. (2006). *Analisis deret waktu: Teori dan aplikasi*. Andira Publisher.
<https://eprints.unm.ac.id/21944/1/ATS%20book.pdf>
- Badan Pusat Statistik. (2020). *Statistik transportasi udara 2019*. Badan Pusat Statistik RI.
<https://www.bps.go.id/id/publication/2020/11/20/231373341461207b51910a4a/statistik-transportasi-udara-2019.html>

- Badan Pusat Statistik. (2026). *Jumlah penumpang pesawat (angkutan udara) domestik di 5 bandara utama (orang)* [Tabel Statistik]. BPS RI. Diakses pada 24 Oktober 2026, dari <https://www.bps.go.id/id/statistics-table/2/MjM0OSMy/jumlah-penumpang-pesawat--angkutan-udara--domestik-di-5-bandara-utama--orang-.html>
- Badan Pusat Statistik Provinsi Bali. (2023). *Provinsi Bali dalam angka 2023*. <https://bali.bps.go.id/publication/2023/02/28/b467b61cc7b43c86916a11db/provinsi-bali-dalam-angka-2023.html>
- Badan Pusat Statistik Provinsi Bali. (2026). *Statistik transportasi udara dan laut Provinsi Bali 2025* (Katalog BPS No. 8303004). BPS Provinsi Bali. <https://bali.bps.go.id/id/publication/2026/04/29/db2575bb0f7b1ccd168b92c6/statistik-transportasi-udara-dan-laut-provinsi-bali-2025.html>
- Baskara, A. K., Nazir, A., Irsyad, M., Yusra, & Insani, F. (2023). Implementasi data mining memprediksi penjualan crude palm oil berdasarkan kapasitas tangki menggunakan Multiple Linear Regression. *Jurnal Sistem Komputer dan Informatika (JSON)*, 4(3), 493–502. <https://doi.org/10.30865/json.v4i3.5665>
- Butarbutar, W., Van Delsen, M. S. N., & Djami, R. J. (2023). Application of the Seasonal Autoregressive Integrated Moving Average (SARIMA) method to forecast the number of vessel passenger departures at Yos Soedarso Ambon Port. *Tensor: Pure and Applied Mathematics Journal*, 4(2), 105–118. <https://doi.org/10.30598/tensorvol4iss2pp105-118>
- Cryer, J. D., & Chan, K.-S. (2008). *Time series analysis: With applications in R* (2nd ed.). Springer. <https://doi.org/10.1007/978-0-387-75959-3>
- Durrah, F. I., Yulia, Parhusip, T. P., & Rusyana, A. (2018). Peramalan jumlah penumpang pesawat di Bandara Sultan Iskandar Muda dengan metode SARIMA (Seasonal Autoregressive Integrated Moving Average). *Journal of Data Analysis*, 1(1), 1–11. <https://doi.org/10.24815/jda.v1i1.11847>
- Gunawan, W., & Ramadani, M. (2023). Analisa perbandingan penerapan metode SARIMA dan Prophet dalam memprediksi persediaan barang PT XYZ. *Faktor Exacta*, 16(2), 88–97. <https://doi.org/10.30998/faktorexacta.v16i2.13803>
- Herdianto. (2013). *Prediksi kerusakan motor induksi menggunakan metode jaringan saraf tiruan backpropagation* [Tesis, Universitas Sumatera Utara]. <https://repository.usu.ac.id/handle/123456789/38400>
- Kementerian Perhubungan Republik Indonesia. (2023, 18 Januari). *Kualitas infrastruktur transportasi di Bali terus ditingkatkan*. <https://dephub.go.id/index.php/post/read/kualitas-infrastruktur-transportasi-di-bali-terus-ditingkatkan>
- Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworth Scientific. <https://archive.org/details/industrialbusine0000lewi>
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and applications* (3rd ed.). John Wiley & Sons. <https://bcs.wiley.com/he-bcs/Books?action=contents&bcsId=7079&itemId=0471532339>
- Muzakki, M. A., Sabila, M. A., Sundari, S., & Wisnuadhi, B. (2021). Analisis algoritma Prophet untuk memprediksi harga pangan di Kota Bandung. *Prosiding Industrial Research Workshop and National Seminar*, 12, 659–664. <https://jurnal.polban.ac.id/proceeding/article/view/2777>
- Nuha, H. (2023). *Mean absolute percentage error (MAPE) dan pengertiannya* [Pracetak]. SSRN. <https://ssrn.com/abstract=4422741>
- Nur Aziza, V., Moh'd, F. H., Maghfiroh, F. A., Notodiputro, K. A., & Angraini, Y. (2023). Performance comparison of SARIMA intervention and Prophet models for forecasting the number of airline passenger at Soekarno-Hatta International Airport. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 17(4), 2107–2120. <https://doi.org/10.30598/barekengvol17iss4pp2107-2120>

- Nurvianti, I., Setiawan, B. D., & Bachtiar, F. A. (2019). Perbandingan peramalan jumlah penumpang keberangkatan kereta api di DKI Jakarta menggunakan metode Double Exponential Smoothing dan Triple Exponential Smoothing. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(6), 5257–5263. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/download/5458/2567/37817>
- Rahmawati, D. H. (2024). *Implementasi model Prophet untuk peramalan jumlah penumpang harian pesawat Citilink Bengkulu–Jakarta dan Jakarta–Bengkulu pada periode pandemi* [Skripsi, UIN Syarif Hidayatullah Jakarta]. <https://repository.uinjkt.ac.id/dspace/handle/123456789/81176>
- Ridla, M. A., Azise, N., & Rahman, M. (2023). Perbandingan model time series forecasting dalam memprediksi jumlah kedatangan wisatawan dan penumpang airport. *SIMKOM*, 8(1), 1–14. <https://doi.org/10.51717/simkom.v8i1.103>
- Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37–45. <https://doi.org/10.1080/00031305.2017.1380080>
- Wei, W. W. S. (2023). *Time series analysis: Univariate and multivariate methods* (Classic Version, 2nd ed.). Pearson. <https://www.pearson.com/en-us/subject-catalog/p/time-series-analysis-univariate-and-multivariate-methods-classic-version/P200000006412/9780134995366>