

PENERAPAN MODEL HYBRID ARIMA-GARCH DALAM PERAMALAN JUMLAH WISATAWAN DOMESTIK KE BALI

Putu Ngurah Harimbawa

Program Studi Matematika, FMIPA, Universitas Pendidikan Ganesha, Singaraja, Indonesia

e-mail: harimbawa@undiksha.ac.id*

I Gusti Putu Suharta

Program Studi Pendidikan Matematika, FMIPA, Universitas Pendidikan Ganesha, Singaraja, Indonesia

e-mail: putu.suharta@undiksha.ac.id

Putu Kartika Dewi

Program Studi Matematika, FMIPA, Universitas Pendidikan Ganesha, Singaraja, Indonesia

e-mail: kartika.dewi@undiksha.ac.id

Abstrak

Pariwisata merupakan sektor strategis dalam perekonomian Bali. Namun, ketergantungan tinggi terhadap wisatawan mancanegara menyebabkan kerentanan saat krisis, seperti pandemi *Covid-19*. Oleh karena itu, diversifikasi terhadap wisatawan domestik menjadi strategi penting, sehingga perencanaan yang tepat ini memerlukan dukungan model peramalan yang akurat. Data jumlah wisatawan domestik cenderung memiliki volatilitas data yang tidak konstan dan bersifat *heteroskedastisitas*, seperti lonjakan saat musim liburan dan penurunan akibat kebijakan pembatasan, yang menyebabkan perubahan varians residual secara dinamis. Oleh karena itu, diperlukan pendekatan peramalan yang mampu menangkap pola linier sekaligus memodelkan volatilitas bersyarat dalam data. Penelitian ini bertujuan untuk mengevaluasi keakuratan model hybrid ARIMA-GARCH dalam meramalkan jumlah wisatawan domestik bulanan yang berkunjung ke Bali. Model ARIMA digunakan untuk menangkap pola linier jangka panjang, sedangkan GARCH digunakan untuk memodelkan volatilitas bersyarat. Data yang digunakan adalah data bulanan jumlah wisatawan domestik periode Januari 2004 hingga Desember 2024. Model terbaik yang diperoleh adalah ARIMA(2,1,4)-GARCH(1,0), dipilih berdasarkan nilai AIC dan SIC terkecil serta memenuhi uji diagnostik model. Evaluasi akurasi menunjukkan nilai MAE sebesar 129.524 dan nilai MAPE sebesar 16,15%, yang termasuk kategori akurat. Hasil peramalan digunakan untuk memproyeksikan jumlah wisatawan domestik periode Januari 2025 hingga Desember 2026. Temuan ini menunjukkan bahwa model ARIMA-GARCH efektif dalam menangani data wisatawan yang bersifat volatil dan dapat digunakan sebagai dasar pengambilan keputusan dalam kebijakan pariwisata berbasis data di Bali.

Kata Kunci: ARIMA-GARCH, peramalan, wisatawan domestik, volatilitas, Bali

Abstract

Tourism is a strategic sector in Bali's economy. However, its heavy reliance on international tourists makes it vulnerable during crises, such as the Covid-19 pandemic. Consequently, diversification toward domestic tourism has become a crucial strategy, which in turn requires effective planning supported by accurate forecasting models. The number of domestic tourist arrivals tends to exhibit non-constant volatility and heteroskedasticity, such as surges during holiday seasons and declines due to travel restrictions, resulting in dynamically changing residual variances. Therefore, a forecasting approach that captures both linear patterns and conditional volatility is essential. This study aims to evaluate the accuracy of the hybrid ARIMA-GARCH model in forecasting the monthly number of domestic tourists visiting Bali. The ARIMA model is employed to identify long-term linear trends, while the GARCH model is used to model conditional volatility. The data used in this study consist of monthly domestic tourist arrivals from January 2004 to December 2024. The best-fitting model obtained is ARIMA(2,1,4)-GARCH(1,0), selected based on the lowest AIC and SIC values and validated through diagnostic tests. Accuracy evaluation shows a Mean Absolute Error (MAE) of 129,524 and a Mean Absolute Percentage Error (MAPE) of 16.15%, which falls into the category of accurate forecasts. The model is then used to project domestic tourist numbers from January 2025 to December 2026. These findings demonstrate that the ARIMA-GARCH model is effective in handling volatile tourism data and can serve as a reliable tool for data-driven tourism policy planning in Bali.

Keywords: ARIMA-GARCH, forecasting, domestic tourists, volatility, Bali

PENDAHULUAN

Pariwisata merupakan sektor strategis dalam perekonomian Indonesia, berkontribusi signifikan terhadap pendapatan nasional serta menciptakan jutaan lapangan kerja. Pemerintah menjadikan pariwisata sebagai sektor unggulan karena potensinya dalam mendorong pertumbuhan ekonomi (Fuqoha, 2021). Data dari BPS menunjukkan bahwa pada Februari 2024 terdapat 1,03 juta kunjungan wisatawan mancanegara, meningkat 11,67% dari bulan sebelumnya dan naik 38,24% dibandingkan periode yang sama tahun lalu (Sugianto, 2024). Slogan *“Wonderful Indonesia”* mencerminkan kekayaan dan keberagaman destinasi wisata nasional, yang turut memperkuat diplomasi budaya dan hubungan internasional.

Salah satu destinasi pariwisata Indonesia yang paling menonjol di mata dunia adalah Bali. Keindahan alam yang memukau, kekayaan budaya, serta tradisi masyarakatnya menjadikan Bali sebagai magnet utama bagi wisatawan mancanegara (Putra dkk., 2022). Sebelum pandemi, Bali mencatat 10,5 juta kunjungan wisatawan, dengan wisatawan asing menyumbang sekitar 70% dari total pendapatan sektor ini (Anggreni & Budiasih, 2023). Ketergantungan tinggi terhadap wisatawan asing terbukti menjadi kerentanan saat pandemi, yang menyebabkan penurunan kunjungan hingga 80% pada 2020. Dampak pandemi ini mendorong berbagai pihak untuk mengevaluasi kembali arah pengembangan sektor pariwisata. Penelitian oleh (Larasdiputra dkk., 2022) menunjukkan bahwa pandemi telah membangkitkan kesadaran kolektif bahwa Bali tidak dapat terus bergantung sepenuhnya pada pariwisata massal yang didominasi wisatawan mancanegara. Dalam studi tersebut, mereka menekankan pentingnya pengembangan ekowisata dan desa wisata sebagai bentuk diversifikasi pasar menuju wisatawan domestik, yang tidak hanya berpotensi menggerakkan ekonomi lokal, tetapi juga mendukung keberlanjutan lingkungan dan pelestarian budaya.

Namun, kontribusi wisatawan domestik pasca pandemi masih belum optimal, terutama karena keterbatasan data pola perjalanan dan strategi pemasaran berbasis data yang belum berkembang. Hal ini sejalan dengan temuan (Arismayanti dkk., 2024), yang menyatakan bahwa destinasi seperti Bali

sangat bergantung pada kunjungan wisatawan mancanegara. Oleh karena itu, pemulihan pasca pandemi menuntut manajemen destinasi yang lebih adaptif, dengan pendekatan berbasis data yang akurat dalam memahami pengalaman dan persepsi wisatawan sebagai dasar perumusan strategi pemasaran dan inovasi layanan. Konsentrasi pengembangan destinasi di wilayah tertentu seperti Kuta, Ubud, dan Nusa Dua, menyebabkan lebih dari 1.400 desa wisata belum tergarap maksimal. Hanya sekitar 30 desa wisata yang menunjukkan perkembangan signifikan menurut data Dinas Pariwisata Provinsi Bali (Maharani, 2024). Oleh karena itu, diperlukan analisis berbasis data untuk memahami perilaku wisatawan domestik dan mendistribusikan promosi secara lebih merata.

Dalam konteks pengembangan sektor pariwisata, peramalan jumlah wisatawan domestik menjadi elemen krusial untuk menunjang perencanaan yang lebih terarah dan efisien. Proses peramalan sendiri merujuk pada teknik prediksi berbasis analisis data historis guna mengidentifikasi pola serta tren perjalanan wisata (Aditya dkk., 2023). Salah satu pendekatan yang paling umum digunakan dalam peramalan data adalah metode *time series*, yang mengandalkan informasi masa lampau untuk memperkirakan kejadian di masa mendatang (Anitya dkk., 2024). Dengan menerapkan model peramalan yang andal dan akurat, para pemangku kepentingan dapat lebih siap menghadapi kemungkinan penurunan jumlah kunjungan. Selain itu, informasi dari hasil peramalan juga dapat dimanfaatkan untuk menyusun strategi mitigasi yang tepat serta mengarahkan investasi infrastruktur ke sektor-sektor yang paling membutuhkan (Indradewi dkk., 2022). Dengan pendekatan berbasis data yang presisi, sektor pariwisata domestik diharapkan dapat lebih adaptif dan berkontribusi signifikan terhadap pemulihan ekonomi.

Salah satu metode peramalan yang banyak digunakan adalah ARIMA, yang unggul dalam mengidentifikasi pola linier deret waktu (Hartawan dkk., 2023). Meski demikian, ARIMA memiliki keterbatasan dalam menangkap volatilitas data yang tinggi, seperti lonjakan kunjungan saat musim libur. Untuk itu, model ini perlu dikombinasikan dengan pendekatan yang mampu mengatasi heteroskedastisitas, seperti GARCH (Putri dkk., 2021). Model GARCH, hasil pengembangan dari

ARCH, efektif dalam memodelkan data dengan fluktuasi tinggi dan volatilitas bersyarat (Hartanto, 2022).

Model hybrid ARIMA-GARCH menggabungkan keunggulan masing-masing model dalam menangkap pola tren dan fluktuasi. Penelitian (Misengo dkk., 2023) dan (Abdou dkk., 2021) menunjukkan bahwa model ini menghasilkan prediksi yang lebih akurat untuk sektor pariwisata dibanding penggunaan model tunggal. Studi di Indonesia pun mendukung hal ini, seperti penelitian (Ahmad, 2024) dan (Fadhilah dkk., 2024), yang menunjukkan akurasi tinggi dalam peramalan data sektor pariwisata dan keuangan.

Berbeda dengan penelitian-penelitian sebelumnya yang umumnya menerapkan model ARIMA-GARCH dalam bidang keuangan seperti peramalan saham atau return investasi, penelitian ini menghadirkan inovasi dalam konteks sektor pariwisata, khususnya dalam memprediksi jumlah kunjungan wisatawan domestik. Pendekatan ini masih relatif baru di bidang pariwisata dan menunjukkan potensi besar dalam pengelolaan destinasi berbasis data. Dengan kombinasi kekuatan ARIMA dalam mengenali tren serta GARCH dalam menangkap dinamika volatilitas, model ini diharapkan menjadi alat peramalan yang lebih adaptif dan relevan dengan kebutuhan pasca pandemi.

Dengan demikian, peramalan jumlah wisatawan domestik bulanan ke Bali menjadi sangat krusial dalam mendukung strategi diversifikasi pariwisata. Model ARIMA-GARCH menjadi pendekatan yang ideal karena mampu mengakomodasi tren jangka panjang sekaligus volatilitas jangka pendek. Penerapan model ini diharapkan dapat membantu pengambilan keputusan yang lebih efektif dalam pengembangan pariwisata domestik di Bali.

KAJIAN TEORI

KESTASIONERAN

Data dianggap stasioner jika tidak mengalami pertumbuhan atau penurunan yang signifikan, atau dengan kata lain, fluktuasinya bergerak di sekitar rata-rata yang stabil, tidak dipengaruhi oleh waktu, dan memiliki varians yang tetap (Milniadi & Adiwijaya, 2023). Oleh karena itu, langkah awal yang penting dalam analisis deret waktu adalah

memeriksa kestasioneran data berdasarkan rata-rata dan variansinya.

1. Kestasioneran dalam rata-rata

Salah satu metode yang digunakan untuk menguji kestasioneran data adalah uji akar unit dengan pendekatan *Augmented Dickey-Fuller* (ADF). Persamaan *Dickey-Fuller* diterapkan pada model dengan *differencing* dan lag yang diregresikan sebagai bagian dari pengujian ini (Gujarati, 2004).

$$\nabla Z_t = \mu + \delta Z_{t-1} + \sum_{i=1}^k \phi_i \nabla Z_{t-i} + e_t \quad (1)$$

Hipotesis uji (Cerelia dkk., 2021):

$H_0 : \delta = 0$ (data tidak stasioner)

$H_1 : \delta \neq 0$ (data stasioner)

Uji statistik:

$$ADF = \frac{\hat{\delta}}{SE(\hat{\delta})} \quad (2)$$

2. Kestasioneran dalam ragam

Transformasi Box-Cox adalah salah satu metode yang digunakan untuk menstasionerkan data ketika variansnya tidak stabil. Teknik ini menerapkan transformasi pangkat pada variabel respons (Yunita, 2020). Persamaan transformasi *Box-Cox* dinyatakan sebagai berikut (Wei, 2006).

$$T(Z)_t = \frac{Z_t^\lambda - 1}{\lambda}, \lambda \neq 0 \quad (3)$$

$$T(Z)_t = \lim_{\lambda \rightarrow 0} \frac{Z_t^\lambda - 1}{\lambda} = \ln Y_t, \lambda = 0 \quad (4)$$

AUTOCORRELATION FUNCTION (ACF)

ACF merupakan langkah awal dalam menguji korelasi pada data *time series*. Fungsi ini merupakan alat diagnostik penting untuk menganalisis hubungan atau ketergantungan dalam data. Dengan mempertimbangkan asumsi kestasioneran sebelumnya maka fungsi autokorelasi sampel r_k pada lag- k didefinisikan sebagai berikut.

$$r_k = \rho_k = \frac{\sum_{t=1}^{n-k} (z_t - \bar{z})(z_{t+k} - \bar{z})}{\sum_{t=1}^n (z_t - \bar{z})^2}, \text{ untuk } k = 1, 2, \dots \quad (5)$$

PARSIAL AUTOCORRELATION FUNCTION (PACF)

PACF adalah sekumpulan nilai autokorelasi parsial pada berbagai lag- k (Huda dkk., 2023). PACF mengukur hubungan langsung antara Z_t dan Z_{t-k} dengan menghilangkan pengaruh dari lag sebelumnya $(1, 2, \dots, k-1)$. Rumus berikut digunakan untuk menghitung PACF.

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \quad (6)$$

DIAGNOSIS MODEL

Untuk mengevaluasi kecukupan model diperlukan uji diagnosis model dengan menganalisis residual yang dihasilkan.

1. Uji Asumsi *White Noise*

Suatu proses disebut sebagai *white noise* apabila fluktuasi acaknya tidak menunjukkan pola yang sistematis, tidak saling berkorelasi antar waktu, memiliki rata-rata nol, serta varians yang konstan. Uji statistik yang digunakan sebagai berikut.

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)}, n > k \quad (7)$$

Hipotesis uji:

$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$ (residual *white noise*)

$H_1 : \text{paling sedikit terdapat satu } \rho_i \neq 0, i = 1, 2, \dots, k$ (residual tidak *white noise*)

2. Uji Normalitas

Untuk menentukan apakah residual model berdistribusi normal, dapat dilakukan uji kenormalan residual. Salah satu metode yang digunakan untuk pengujian ini adalah uji *Kolmogorov-Smirnov*.

$$JB = \frac{n}{6} \left(S^2 + \frac{(K-3)^2}{4} \right) \quad (8)$$

Hipotesis uji:

$H_0 : \text{Residual dengan distribusi yang normal}$

$H_1 : \text{Residual dengan distribusi yang tak normal}$

3. Uji Heterokedastisitas

Uji heteroskedastisitas bertujuan untuk mendeteksi adanya variabilitas yang tidak konstan dalam model data deret waktu. Salah satu metode yang umum digunakan adalah Uji *Lagrange Multiplier* (ARCH-LM), yang berfungsi untuk mengidentifikasi keberadaan efek ARCH pada galat model ARIMA (Fitriyani, 2021).

$$F = \frac{\frac{SSR_0 - SSR_1}{m}}{SSR_1 / (n - 2m - 1)} \quad (9)$$

Hipotesis uji:

$H_0 : \text{Tidak terdapat pengaruh ARCH pada residual.}$

$H_1 : \text{Terdapat pengaruh ARCH pada residual.}$

KRITERIA PEMILIHAN MODEL TERBAIK

Dalam pemilihan model terbaik, diperlukan kriteria tertentu untuk menilai dan membandingkan beberapa model yang layak serta memenuhi asumsi. Berikut adalah kriteria yang digunakan.

1. Akaike's Information Criterion (AIC)

AIC menyeimbangkan kompleksitas model dengan *goodness-of-fit*, sehingga memungkinkan pemilihan model yang optimal (Sianipar & Hibertus,

2025). Rumusan AIC dinyatakan dalam persamaan berikut.

$$AIC = n \ln \hat{\sigma}_a^2 + 2M \quad (10)$$

2. Schwarz Information Criterion (SIC)

SIC juga dikenal sebagai *Bayesian Information Criterion* (BIC), adalah metode untuk memilih model terbaik dalam statistik dan *machine learning* berdasarkan keseimbangan antara kompleksitas model dan kecocokan data. Rumusan SIC dinyatakan dalam persamaan berikut.

$$SIC = n \ln \hat{\sigma}_a^2 + M \ln n \quad (11)$$

EVALUASI PERAMALAN

Peramalan bertujuan memprediksi kondisi masa depan berdasarkan data historis, namun hasilnya tidak selalu 100% akurat. Oleh karena itu, penting untuk meminimalkan tingkat kesalahan dan memastikan model yang digunakan memiliki akurasi dan keandalan tinggi (Megayasa dkk., 2022)

1. Mean Absolute Percentage Error (MAPE)

Untuk mengukur tingkat kesalahan peramalan dalam bentuk persentase, yang dihitung menggunakan rumus berikut.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{F_t - Z_t}{Z_t} \right| \times 100\% \quad (12)$$

2. Mean Absolut Error (MAE)

Persamaan untuk menentukan MAE adalah sebagai berikut.

$$MAE = \frac{1}{n} \sum_{t=1}^n |Z_t - F_t| \quad (13)$$

MODEL ARIMA

Model ARIMA merupakan salah satu model deret waktu yang sedang berkembang dan umum digunakan yang diperkenalkan dan dikembangkan oleh George Box dan Gwilym Jenkins pada tahun 1960-an (Susilawati & Sunendiari, 2022). ARIMA adalah suatu model yang digunakan pada data yang telah stasioner, dalam arti data telah melalui proses pembedaan (*differencing*), maka dari itu data sudah stasioner. Secara umum model ARIMA (p, d, q) dapat dituliskan sebagai berikut.

$$(1 - B)^d Z_t = (B) a_t \quad (14)$$

Persamaan diatas jika dirumuskan menggunakan operator *backshift* (B), maka:

$$1 - B^d 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p Z_t = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B a_t \quad (15)$$

Sehingga didapatkan:

$$1 - B^d Z_t - \phi_1 Z_{t-1} - \dots - \phi_p Z_{t-p} = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (16)$$

MODEL ARCH

Model ARCH bersifat dinamis dan dirancang untuk menangani varians *error* yang tidak konstan dalam data runtun waktu. Model ini hanya memerlukan satu variabel deret waktu, tanpa mempertimbangkan faktor eksternal. Peramalan dilakukan dengan asumsi bahwa varians masa depan dipengaruhi oleh kuadrat residual dari periode sebelumnya (Laila Budianti, 2024). Bentuk umum dari model ARCH adalah sebagai berikut.

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \alpha_2 e_{t-2}^2 + \alpha_p e_{t-p}^2 \quad (17)$$

MODEL GARCH

Model GARCH merupakan pengembangan dari model ARCH yang diperkenalkan oleh Bollerslev pada tahun 1986. Model ini dirancang untuk menangani heteroskedastisitas dalam data deret waktu (*time series*) dengan mempertimbangkan pengaruh varian residual dari periode sebelumnya. Bentuk umum model GARCH adalah sebagai berikut.

$$\sigma_t^2 = \omega + \sum_{j=1}^q \alpha_j \sigma_{t-j}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2 \quad (18)$$

METODE

Penelitian ini merupakan penelitian terapan dengan pendekatan kuantitatif, yang bertujuan untuk meramalkan jumlah wisatawan domestik bulanan ke Bali. Data yang digunakan berupa data sekunder dari Badan Pusat Statistik (BPS) Provinsi Bali, dengan periode Januari 2004 hingga Desember 2024. Variabel yang dianalisis adalah jumlah wisatawan domestik per bulan. Data dibagi menjadi dua bagian: data *training* (Januari 2004 – Desember 2023) untuk pembentukan model, dan data *testing* (Januari – Desember 2024) untuk evaluasi akurasi.

Dikarenakan karakteristik data cukup kompleks dan memerlukan ketelitian tinggi dalam analisis, penelitian ini menggunakan bantuan perangkat lunak *R-Studio* untuk menghindari kesalahan perhitungan dan mempermudah proses analisis deret waktu.

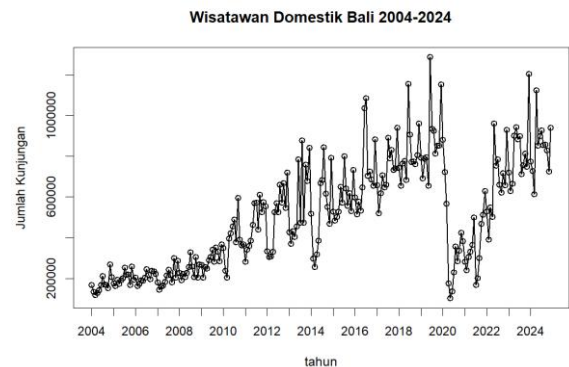
Teknik analisis dilakukan dalam beberapa tahapan utama sebagai berikut.

1. Import data
2. Visualisasi plot *series* data jumlah wisatawan domestik bulanan ke Bali.
3. Uji kestasioner data

4. Identifikasi model ARIMA dan Penafsiran parameter
5. Estimasi model ARIMA
6. Identifikasi efek ARCH –GARCH (heteroskedastisitas)
7. Estimasi model ARIMA-GARCH
8. Evaluasi model ARIMA-GARCH
9. Peramalan

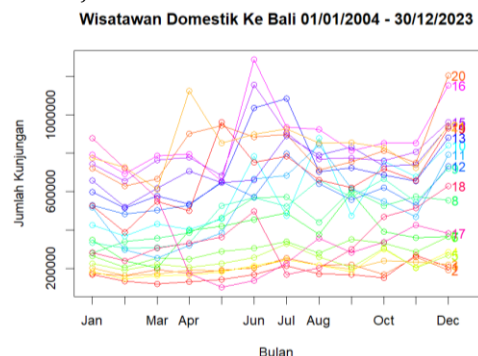
HASIL DAN PEMBAHASAN

Eksplorasi data awal dilakukan dengan merubah data menjadi data *time series*. Hasil eksplorasi data disajikan pada Gambar 1.



Gambar 1. Data jumlah wisatawan domestik ke Bali

Gambar 1 menunjukkan pola fluktuatif dalam jumlah kunjungan wisatawan domestik, dengan tren awal yang meningkat lalu menurun. Variabilitas yang tidak stabil di sekitar rata-rata mengindikasikan potensi ketidakstasioneran data. Oleh karena itu, identifikasi awal terhadap komponen tren dan musiman diperlukan untuk menentukan strategi transformasi dan pemodelan yang tepat dalam analisis lanjutan.



Gambar 2. Identifikasi pola data

Eksplorasi awal terhadap data kunjungan wisatawan domestik ke Bali periode 2004–2024 menunjukkan tidak adanya pola musiman maupun

tren yang signifikan. Pola fluktuatif antar bulan dan tahun cenderung tidak konsisten, sehingga tidak memenuhi karakteristik deret waktu dengan komponen musiman atau tren jangka panjang. Dengan demikian, pendekatan pemodelan ARIMA non-musiman dianggap tepat untuk menganalisis data ini.

UJI KESTASIONERAN

Untuk memastikan sifat stasioneritas data secara objektif, dilakukan pengujian lanjutan menggunakan uji *Box-Cox* dan uji ADF pada data pelatihan. Pengujian dilakukan terhadap dua aspek utama, yaitu variansi dan rata-rata.

1. Stasioner dalam variansi

Jika data tidak stasioner dalam variansi, maka diperlukan proses transformasi sebelum dilanjutkan ke uji berikutnya. Setelah transformasi diterapkan, uji *Box-Cox* kembali dilakukan untuk memastikan kestabilan data. Hasil pengujian terhadap variansi disajikan dalam Tabel berikut.

Tabel 1. Uji *Box-Cox*

Transformasi	Nilai λ	Keterangan
Sebelum	0.24	Tidak Stasioner
Sesudah	0.98*	Stasioner

*Nilai λ yang mendekati 1

Berdasarkan hasil Uji *Box-Cox* pada Tabel 1, data belum stasioner dalam variansi sebelum dilakukannya transformasi yang ditunjukkan oleh nilai λ sebesar 0,24 yang cukup jauh dari 1. Oleh karena itu, dilakukan transformasi lanjutan. Hasil transformasi pada Tabel 1 menunjukkan nilai optimum λ sebesar 0,98, dengan interval kepercayaan 95% antara 0,15 hingga 1,81. Karena interval ini mencakup nilai 1, maka dapat disimpulkan bahwa data telah memenuhi asumsi stasioneritas dalam variansi.

2. Stasioner dalam rata-rata

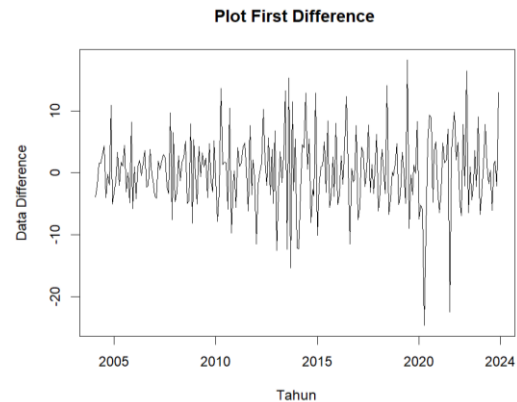
Selanjutnya, pengujian stasioneritas terhadap rata-rata dilakukan menggunakan uji ADF. Jika data dinyatakan tidak stasioner, maka dilakukan proses *differencing*, yang kemudian diikuti dengan uji ulang untuk memastikan kestasioneran. Hasil pengujian terhadap kedua aspek disajikan pada Tabel 2.

Tabel 2. Uji ADF

Uji Kestasioneran	<i>p-value</i>	Keterangan
Pada level $I(0)$	0.1943	Tidak Stasioner
<i>Difference</i> $I(1)$	0.01*	Stasioner

*Parameter yang signifikan pada taraf nyata 5%

Berdasarkan Tabel 2, proses *differencing* cukup dilakukan satu kali, karena hasilnya langsung menunjukkan bahwa data telah stasioner terhadap rata-rata. Hal ini ditunjukkan oleh nilai *p-value* yang lebih kecil dari tingkat signifikansi yang ditetapkan. Visualisasi data setelah *differencing* ditampilkan pada Gambar 3.




Gambar 3. Data stasioner pada rata-rata

Berdasarkan Gambar 3, terlihat bahwa data yang telah melalui proses *differencing* sudah stasioner terhadap rata-rata.


IDENTIFIKASI MODEL ARIMA

Identifikasi model ARIMA (p, d, q) dilakukan melalui analisis *correlogram*, dengan memperhatikan pola signifikan pada plot ACF dan PACF untuk menentukan orde model secara optimal.



Gambar 4. (a) Plot ACF dan (b) Plot PACF

Dan juga berikut tampilan dari plot EACF



Gambar 5. Plot EACF

Pada plot ACF, PACF dan EACF, terdapat beberapa model tentatif yang teridentifikasi, yaitu ARIMA(1,1,2), ARIMA(1,1,4), ARIMA(2,1,3), dan ARIMA(2,1,4). Tahap selanjutnya adalah melakukan estimasi terhadap keempat model tersebut. Model terbaik kemudian akan dipilih berdasarkan kriteria nilai AIC dan SIC terkecil, serta mempertimbangkan signifikansi dari seluruh parameter yang diestimasi.

ESTIMASI MODEL ARIMA

Tabel 3. Hasil Estimasi Model

No	Model	Parameter	Coef	p-value
1.	ARIMA (1,1,2)	ϕ_1	0.547	8e-10*
		θ_1	-1.849	<2e-16*
		θ_2	0.849	<2e-16*
2.	ARIMA (1,1,4)	ϕ_1	0.358	0.0206*
		θ_1	-1.70	<2.2e-16*
		θ_2	0.846*	0.0001*
		θ_3	-0.379	0.0101*
		θ_4	0.233	0.0014*
3.	ARIMA (2,1,3)	ϕ_1	-0.357	0.0045*
		ϕ_2	0.555	9.8e-10*
		θ_1	-0.956	5.5e-16*
		θ_2	-0.826	5.4e-6*
		θ_3	0.480	<2.2e-16*
4.	ARIMA (2,1,4)	ϕ_1	0.825	5.04e-16*
		ϕ_2	-0.565	0.2256*
		θ_1	-2.167	<2.2e-16
		θ_2	2.024	4.6e-5*
		θ_3	-1.262	0.0018*
		θ_4	0.406	2.8e-5*

*Parameter yang signifikan pada taraf nyata 5%

Berdasarkan hasil uji signifikansi, keempat model ARIMA yang diestimasi menunjukkan parameter yang signifikan. Oleh karena itu, tahap selanjutnya adalah memilih model terbaik dengan

mempertimbangkan nilai kriteria informasi, yaitu AIC dan SIC terlihat pada tabel 4 berikut.

Tabel 4. Hasil Estimasi Model

Model	AIC	SIC
ARIMA(1,1,2)	1523.54	1537.42
ARIMA(1,1,4)	1519.49	1540.32
ARIMA(2,1,3)	1524.39	1545.23
ARIMA(2,1,4)	1517.29	1541.6

Berdasarkan Tabel 4, model ARIMA(2,1,4) dipilih sebagai model terbaik karena memiliki nilai AIC terendah, yaitu 1519,49 yang menunjukkan keseimbangan optimal antara kompleksitas model dan kecocokan terhadap data.

DIAGNOSTIK MODEL

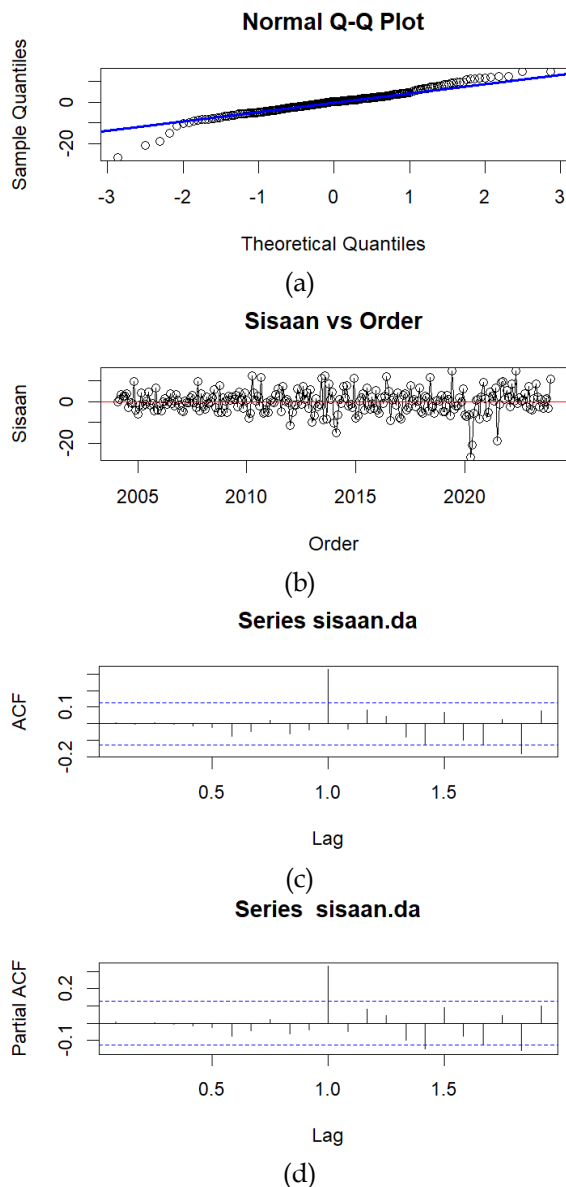
Setelah diperoleh model ARIMA(2,1,4) dengan seluruh parameter signifikan, dilakukan tahapan diagnosis residual (sisaan) untuk memastikan bahwa model telah memenuhi asumsi dasar. Diagnosis ini mencakup uji *white noise* menggunakan *Ljung-Box*, uji normalitas menggunakan *Kolmogorov-Smirnov*, serta uji rata-rata sisaan menggunakan *One Sample t-test*.

Tabel 5. Uji Diagnostik Model

Uji Ljung - Box	
<i>X-squared</i>	0.009
<i>p-value</i>	0.920
Keterangan	White Noise
Uji Kolmogorov - Smirnov	
<i>D</i>	0.0637
<i>p-value</i>	0.0106
Keterangan	Tidak Normal
Uji One Sample t-test	
<i>t-statistik</i>	-0.0824
<i>p-value</i>	0.9344
Keterangan	Tidak signifikan; mean ≈ 0

Uji Ljung-Box menunjukkan residual model ARIMA(2,1,4) bersifat *white noise* yang berarti tidak terdapat pola berulang dalam sisaan, uji *One Sample t-test* menunjukkan rata-rata sisaan tidak berbeda signifikan dari nol yang menandakan model telah memenuhi asumsi bahwa sisaan bersifat acak dan tidak bias, sedangkan uji *Kolmogorov-Smirnov* mengindikasikan sisaan tidak normal secara

distribusi, sehingga diperlukan uji lanjutan untuk mengidentifikasi potensi *heteroskedastisitas*.



Gambar 6. (a) Q-Q plot normalitas, (b) Homogen Residual, (c) ACF dan (d) PACF Residual model ARIMA(2,1,4)

Q-Q plot menunjukkan residual model ARIMA(2,1,4) tidak berdistribusi normal, ditandai dengan penyimpangan titik pada ujung plot. Pola pita sisaan yang tidak seragam mengindikasikan *heteroskedastisitas*, meskipun plot ACF dan PACF menunjukkan residual bersifat bebas hingga 20 lag awal. kemudian diperlukan estimasi lanjutan dengan menggunakan Uji ARCH-LM untuk melihat apakah model memiliki sifat *heteroskedastisitas*.

Tabel 6. Uji ARCH-LM

lag	p-value	lag	p-value	lag	p-value
1.	6.8e-16*	6.	0.0017*	11.	0.0005*
2.	3.1e-5*	7.	0.0033*	12.	0.0009*
3.	9.8e-5*	8.	0.0066*	13.	0.0017*
4.	0.0002*	9.	0.0095*	14.	0.0013*
5.	0.0007*	10.	0.0003*	15.	0.0013*

*Parameter yang signifikan pada taraf nyata 5%

Berdasarkan uji ARCH, seluruh *p-value* untuk lag 1 hingga 15 berada di bawah 0,05, yang mengindikasikan adanya efek ARCH dan *heteroskedastisitas* pada residual model ARIMA(2,1,4). Temuan ini diperkuat oleh hasil uji *homokedastisitas* pada gambar 7.

Box-Ljung test	
data:	(sisaan.da)^2
X-squared =	20.698, df = 1, p-value = 5.376e-06

Gambar 7. Uji Box-Ljung test

Uji *Ljung-Box* terhadap sisaan kuadrat menghasilkan *p-value* < 0,05, menunjukkan adanya volatilitas waktu (efek ARCH) dan ragam sisaan yang tidak homogen. Hal ini mengindikasikan adanya *heteroskedastisitas*, sehingga model dapat dilanjutkan pada pemodelan GARCH.

IDENTIFIKASI MODEL GARCH

Pemilihan model GARCH dilakukan dengan pendekatan *trial and error*, dimulai dari ordo terkecil hingga diuji ke ordo yang lebih tinggi. Dari proses ini, diperoleh model awal terbaik yaitu ARIMA(2,1,4)-GARCH(1,0). Selanjutnya, dilakukan *overfitting* untuk mengevaluasi kemungkinan penambahan ordo *p* atau *q* yang signifikan secara statistik. Seluruh model hasil *overfitting* disajikan untuk dianalisis lebih lanjut. Hasil estimasi parameter untuk keempat model secara lengkap ditampilkan pada Tabel berikut.

1. ARIMA(2,1,4)-GARCH(1,0)

Tabel 7. Hasil Estimasi Model

Parameter	Coef	p-value	Keterangan
ϕ_1	0.956	<0.0000*	Signifikan
ϕ_2	-0.966	<0.0000*	Signifikan
θ_1	-1.289	<0.0000*	Signifikan
θ_2	1.210	<0.0000*	Signifikan
θ_3	-0.286	<0.0000*	Signifikan

θ_4	-0.109	<0.0000*	Signifikan
ω_1	0.037	0.0019*	Signifikan
α	0.99	<0.0000*	Signifikan
Loglikelihood	-1413.9		
AIC	11.89		
SIC	12.01		

*Parameter yang signifikan pada taraf nyata 5%

2. ARIMA(2,1,4)-GARCH(0,1)

Tabel 8. Hasil Estimasi Model

Parameter	Coef	p-value	Keterangan
ϕ_1	0.914	<0.0000*	Signifikan
ϕ_2	-0.875	<0.0000*	Signifikan
θ_1	-1.275	<0.0000*	Signifikan
θ_2	1.163	<0.0000*	Signifikan
θ_3	-0.371	<0.0000*	Signifikan
θ_4	-0.097	0.1787	Tidak Signifikan
ω_1	0.075	0.0115*	Signifikan
β_1	0.99	<0.0000*	Signifikan
Loglikelihood	-747.93		
AIC	6.32		
SIC	6.44		

*Parameter yang signifikan pada taraf nyata 5%

3. ARIMA(2,1,4)-GARCH(1,1)

Tabel 9. Hasil Estimasi Model

Parameter	Coef	p-value	Keterangan
ϕ_1	0.828	<0.0000*	Signifikan
ϕ_2	-0.868	<0.0000*	Signifikan
θ_1	-1.352	<0.0000*	Signifikan
θ_2	1.294	<0.0000*	Signifikan
θ_3	-0.477	<0.0000*	Signifikan
θ_4	-0.101	<0.0000*	Signifikan
ω_1	17.61	<0.0000*	Signifikan
α_1	0.553	0.0100*	Signifikan
β_1	0.000	0.9999*	Tidak Signifikan
Loglikelihood	-747.93		
AIC	6.32		
SIC	6.44		

*Parameter yang signifikan pada taraf nyata 5%

4. ARIMA(2,1,4)-GARCH(1,2)

Tabel 10. Hasil Estimasi Model

Parameter	Coef	p-value	Keterangan
ϕ_1	0.828	<0.0000*	Signifikan

ϕ_2	-0.868	<0.0000*	Signifikan
θ_1	-1.352	<0.0000*	Signifikan
θ_2	1.294	<0.0000*	Signifikan
θ_3	-0.477	<0.0000*	Signifikan
θ_4	-0.101	0.0004*	Signifikan
ω_1	17.57	<0.0000*	Signifikan
α_1	0.553	0.0123*	Signifikan
β_1	0.000	0.9999	Tidak Signifikan
β_2	0.001	0.9858	Tidak Signifikan
Loglikelihood	-736.78		
AIC	6.24		
SIC	6.39		

*Parameter yang signifikan pada taraf nyata 5%

Berdasarkan uji parameter menggunakan metode *Maximum Likelihood Estimation*, hanya model ARIMA(2,1,4)-GARCH(1,0) yang seluruh parameternya signifikan secara statistik ($p\text{-value} < 5\%$). Model ini menunjukkan performa signifikan yang lebih baik dibandingkan model hasil *overfitting*, sehingga dipilih sebagai model terbaik dalam penelitian ini. Selanjutnya, dilakukan uji efek ARCH kembali terhadap model ARIMA(2,1,4)-GARCH(1,0) menggunakan uji ARCH-LM untuk memastikan tidak terdapat efek heteroskedastisitas yang tersisa pada sisaan. Uji ini dilakukan sebagai langkah validasi tambahan sebelum model digunakan dalam proses peramalan.

Tabel 11. Uji ARCH-LM

lag	p-value	lag	p-value	lag	p-value
1.	0.8189	6.	0.9994	11.	0.9999
2.	0.9508	7.	0.9998	12.	0.9999
3.	0.9870	8.	0.9999	13.	1
4.	0.9956	9.	0.9999	14.	1
5.	0.9985	10.	0.9999	15.	1

Hasil uji LM-ARCH menunjukkan bahwa model ARIMA(2,1,4)-GARCH(1,0) berhasil mengatasi masalah heteroskedastisitas yang sebelumnya muncul pada model ARIMA tanpa GARCH. Temuan ini diperkuat oleh uji *homokedastisitas* yang ditampilkan pada gambar berikut.

Box-Ljung test	
data: (sisaan)^2	
X-squared = 0.056973, df = 1, p-value = 0.8113	

Gambar 8. Uji Box-Ljung test

Uji *Ljung-Box* terhadap sisaan kuadrat menghasilkan *p-value* sebesar 0,8113 ($> 0,05$), yang mengindikasikan bahwa tidak terdapat autokorelasi pada ragam sisaan. Dengan demikian, dapat disimpulkan bahwa ragam sisaan bersifat homogen (*homoskedastis*), sehingga volatilitas data telah berhasil dimodelkan dengan baik.. Dengan demikian, model ARIMA(2,1,4)-GARCH(1,0) dinilai cukup dalam menangkap dinamika volatilitas. Selanjutnya, estimasi parameter dari Tabel 6 disubstitusikan ke dalam persamaan model ARIMA.

$$Z_t = 1.825Z_{t-1} - 1.39Z_{t-2} + 0.565Z_{t-3} + \alpha_t \\ - 2.167\alpha_{t-1} + 2.024\alpha_{t-2} \\ - 1.262\alpha_{t-3} + 0.406\alpha_{t-4}$$

Dengan,

$$\alpha_t \sim N(0, \sigma_t^2), \text{ dan } \sigma_t^2 = 0.037 + 0.012\alpha_{t-1}^2$$

Setelah diperoleh model ARIMA(2,1,4)-GARCH(1,0) yang memenuhi kriteria estimasi dan diagnosis, langkah selanjutnya adalah melakukan peramalan untuk data *testing* pada Desember 2024. Hasil prediksi ini kemudian dibandingkan dengan data aktual untuk menghitung tingkat *error*. Berikut disajikan hasil peramalan tahun 2024 berdasarkan model tersebut.

Tabel 12. Hasil Peramalan 2024

Periode	Data Asli (Z_t)	Hasil Peramalan (F_t)
Januari	774,529	1,018,323
Februari	726,744	870,244
Maret	612,742	819,594
April	1,124,781	870,210
Mei	852,253	974,230
Juni	898,335	1,024,428
Juli	926,975	965,671
Agustus	853,713	867,483
September	856,370	829,224
Oktober	828,647	882,544
November	724,560	976,445
Desember	941,137	1,013,246

Langkah selanjutnya adalah mengevaluasi tingkat akurasi model dengan menghitung nilai kesalahan (*error*). Metrik yang digunakan untuk evaluasi ini adalah MAPE dan MAE, yang dihitung berdasarkan

hasil peramalan terhadap data aktual pada tahun 2024. Tabel berikut menyajikan hasil perhitungan nilai MAPE dan MAE sebagai indikator kinerja model.

Tabel 13. Hasil Akurasi Model

MAPE	16.15%
MAE	129,524

Dari tabel di atas nilai MAE diperoleh yaitu sebesar 129,524 dan perhitungan MAPE sebesar 16.15% yang sudah tergolong akurat.

Tahap selanjutnya yaitu melakukan peramalan terhadap data wisatawan domestik ke Bali 2 tahun kedepan yaitu dari Januari 2025 hingga Desember 2030 berdasarkan model terbaik yang sudah didapatkan. Berikut merupakan hasil peramalan berdasarkan model ARIMA(2,1,4)-GARCH(1,0).

Tabel 14. Hasil Peramalan 2025 dan 2026

Bulan	Tahun	
	2025	2026
Januari	953,340	933,837
Februari	866,127	866,707
Maret	838,682	856,607
April	893,365	910,759
Mei	977,260	975,629
Juni	1,002,525	982,860
Juli	942,783	926,345
Agustus	865,939	868,245
September	847,843	864,898
Oktober	902,742	917,512
November	976,915	973,600
Desember	992,371	974,039

PENUTUP

KESIMPULAN

Berdasarkan hasil analisis terhadap data wisatawan domestik yang berkunjung ke Bali, diperoleh model terbaik yaitu ARIMA(2,1,4)-GARCH(1,0) yang terbukti mampu menangkap pola dan volatilitas data dengan baik. Model ini memiliki tingkat akurasi yang cukup tinggi, ditunjukkan oleh nilai MAE sebesar 129.524 dan MAPE sebesar 16,15% berdasarkan hasil prediksi tahun 2024, yang

tergolong akurat. Peramalan untuk tahun 2025 hingga 2026 menunjukkan bahwa jumlah kunjungan tertinggi diperkirakan terjadi pada bulan Juni 2025 sebesar 1,002,525 pengunjung, sedangkan jumlah terendah diperkirakan pada bulan Maret 2025 sebesar 838,682 pengunjung.

SARAN

Berdasarkan hasil penelitian ini, disarankan agar peneliti selanjutnya menerapkan model ARIMA-GARCH pada sektor-sektor yang masih jarang dijadikan objek kajian, seperti lingkungan (kualitas udara, curah hujan ekstrem), energi terbarukan (*output* listrik panel surya, turbin angin), maupun transportasi publik (volume penumpang harian), karena sektor-sektor tersebut memiliki pola data yang fluktuatif dan volatil. Selain itu, penggunaan variabel eksternal yang relevan seperti cuaca, kalender liburan, atau faktor sosial-ekonomi juga dapat dipertimbangkan untuk meningkatkan akurasi model.

DAFTAR PUSTAKA

- Abdou, M., Edouard, M., & Musahara, H. (2021). Tourism Demand Modelling and Forecasting: A Review of Literature . *African Journal of Hospitality, Tourism and Leisure*, 10(4), 1370–1393.
- Aditya, M. W., Sukajaya, I. N., & Gunadi, I. G. A. (2023). Forecasting Jumlah Pasien DBD di BRSUD Kabupaten Tabanan Menggunakan Metode Regresi Linier. *Bali Medika Jurnal*, 10(1), 1–12. <https://doi.org/10.36376/bmj.v10i1.290>
- Anggreni, N. W., & Budiasih, N. G. A. N. (2023). Pengaruh Jumlah Kunjungan Wisatawan Domestik dan Mancanegara Terhadap Pendapatan Asli Daerah (PAD) Provinsi Bali Tahun 2019-2022. *Jurnal Kajian dan Terapan Pariwisata*, 4(1), 1–11. <https://doi.org/10.53356/diparojs.v4i1.82>
- Anitya, L., Astawa, I. W. P., & Pujawan, I. G. N. (2024). Perbandingan Single Moving Average dan Single Exponential Smoothing dalam Peramalan Produksi Kopi. *Wahana Matematika dan Sains: Jurnal Matematika, Sains, dan Pembelajarannya*, 17(3), 1–11. <https://doi.org/10.23887/wms.v17i3.68903>
- Arismayanti, N. K., Andiani, N. D., & Kusyanda, M. R. (2024). Tourist satisfaction model: Structural relationship of destination image, electronic word of mouth, and service quality in Bali destination. *Nurture*, 18(2), 360–372. <https://doi.org/10.55951/nurture.v18i2.623>
- Fadhilah, D. N., Kankan Parmikanti, & Budi Nurani Ruchjana. (2024). Peramalan Return Saham Subsektor Perbankan Menggunakan Model ARIMA-GARCH. *Jurnal Fourier*, 13(1), 1–19. <https://doi.org/10.14421/fourier.2024.131.1-19>
- Fitriyani, F., Fasya, S. A., Irfan, M. R., & Ammar, T. T. (2021). Peramalan Indeks Harga Saham PT Verena Multi Finance Tbk Dengan Metode Pemodelan ARIMA Dan ARCH-GARCH. *Jurnal Statistika*, 14(1), 11–23.
- Fuqoha, F. (2021). Analisis Kebijakan Pemerintah Daerah Kota Cilegon Dalam Penetapan Desa Wisata Watu Lawang. *Jurnal Ilmu Administrasi Negara ASIAN (Asosiasi Ilmuwan Administrasi Negara)*, 9(1), 199–217. <https://doi.org/10.47828/jianaasian.v9i1.57>
- Gujarati, D. N. (2004). *Basic econometrics*. (4th ed). McGraw-Hill.
- Hartanto, B. (2022). Analisis Prediksi Indeks Saham Syariah Indonesia (ISSI) Menggunakan Metode Garch. *JURNALEKONOMIKA45*, 10(1), 281–288.
- Hartawan, I. G. N., Pujawan, I. G. N., Pranata, K. M., & Jayanta, K. (2023). Forecasting Population Mortality Rates Using Generalized Lee-Carter Model. *Enthusiastic: International Journal of Applied Statistics and Data Science*, 16–24. <https://doi.org/10.20885/enthusiastic.vol3.iss1.art2>
- Huda, M., Azizah, R. N. N., & Setyana, A. N. (2023). Implementasi Metode ARMA dalam Peramalan Inflasi Provinsi Banten Periode Tahun 2018 sampai Tahun 2023. *Jurnal Bayesian: Jurnal Ilmiah Statistika dan Ekonometrika*, 3(2), 210–221.
- Indradewi, I. G. A. A. D., Mulyani, N. P. S., & Parwita, W. G. S. (2022). Forecasting Room Occupancy Rates Based on Hotel Class in Bali Using the ARIMA Method. *CESS (Journal of Computer Engineering, System and Science)*, 7(2), 325. <https://doi.org/10.24114/cess.v7i2.33959>
- Laila Budianti, J. M. Y. A. A. K. P. G. D. (2024). Pemodelan SARIMA dengan Pendekatan ARCH/GARCH untuk Meramalkan Penjualan Ritel Barang Elektronik. *INNOVATIVE: Journal Of Social Science Research*, 4(1), 1037–1051.
- Larasdiputra, G. D., Jayawarsa, A. A. K., & Darmawan, N. A. S. (2022). Post-Covid-19 Tourism In Bali: The Economy And Eco-Tourism. *Journal of Tourism Economics and Policy*, 2(2), 79–85. <https://doi.org/10.38142/jtep.v2i2.343>
- Maharani, Z. (2024). Perancangan sentra agrowisata di Desa Catur, Kabupaten Bangli, Bali dengan

- pendekatan kontekstual. *E-Journal Universitas Atma Jaya Yogyakarta*.
- Megayasa, I. G. P., Candiasa, I. M., & Dantes, G. R. (2022). Analisis Perkiraan Biaya F&B (Makanan & Minuman) Dengan Metode Moving Average Pada Pola E-Commerce Hotel XYZ. *Journal of Information System Research (JOSH)*, 4(1), 132–137. <https://doi.org/10.47065/josh.v4i1.2254>
- Milniadi, A. D., & Adiwijaya, N. O. (2023). Analisis Perbandingan Model ARIMA dan LSTM dalam Peramalan Harga Penutupan Saham (Studi Kasus: 6 Kriteria Kategori Saham Menurut Peter Lynch). *SIBATIK JOURNAL: Jurnal Ilmiah Bidang Sosial, Ekonomi, Budaya, Teknologi, dan Pendidikan*, 2(6), 1683–1692. <https://doi.org/10.54443/sibatik.v2i6.798>
- Misengo, E. E., Prastyo, D. D., & Kuswanto, H. (2023). Modeling and forecasting monthly tourist arrivals to the United States and Indonesia using ARIMA hybrids of multilayer perceptron models. 080001. <https://doi.org/10.1063/5.0105680>
- Putra, I. P. W. A., Citra, I. P. A., & Nugraha, A. S. A. (2022). Tingkat Kesiapan Obyek Wisata dan Kunjungan Wisatawan di Kawasan Pariwisata Lovina pada Masa New Normal. *Jurnal Pendidikan Geografi Undiksha*, 10(1), 89–102. <https://doi.org/https://doi.org/10.23887/jpg.v10i1.39715>
- Putri, F. T. A., Zukhronah, E., & Pratiwi, H. (2021). Model ARIMA-GARCH Pada Peramalan Harga Saham PT. Jasa Marga (Persero). *Business Innovation and Entrepreneurship Journal*, 3(3), 164–170. <https://doi.org/10.35899/biej.v3i3.308>
- Sianipar, & Hibertus, A. (2025). Penentuan Model Terbaik dalam Pengaruh Lapangan Usaha dan Nilai Ekspor Terhadap Pertumbuhan Ekonomi di Indonesia. *AKSIOMA: Jurnal Sains Ekonomi dan Edukasi*, 2(1), 1–11. <https://doi.org/10.62335/m058dk21>
- Sugianto, S. A. Z. M. E. A. (2024). Kontribusi Sektor Pariwisata Halal terhadap Produk Domestik Bruto (PDB)dalam Membangun Perekonomian Berkelanjutan. *Mutawasith: Jurnal Hukum Islam*, 7(2), 107–132.
- Susilawati, R., & Sunendiari, S. (2022). Peramalan Jumlah Penumpang Kereta Api Menggunakan Metode Arima dan Grey System Theory. *Jurnal Riset Statistika*, 1–13. <https://doi.org/10.29313/jrs.vi.603>
- Tanjung, A. A., Mulyani, & Sari, D. P. (2024). Analisis Volatilitas Saham Sektor Industri Pariwisata di Indonesia. *Senashtek 2024*, 2(1), 492–499.
- Wei, W. W. S. (2006). Time Series Analysis: Univariate and Multivariate Methods, 2nd edition, 2006. California: Addison-Wesley Publishing Company, 1–634.
- Yunita, T. (2020). Peramalan Jumlah Penggunaan Kuota Internet Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA). *Journal of Mathematics: Theory and Applications*, 16–22. <https://doi.org/10.31605/jomta.v2i1.777>