

PERBANDINGAN PERFORMA MODEL ARIMA-GARCH DAN LSTM DALAM MERAMALKAN JUMLAH KUNJUNGAN WISATAWAN DANAU KASTOBA

Dalilah Husna¹, Jasmita Yasmin², Avrel Chesia Berbina³, Fadhilah Yumna⁴, Muhammad Ali Uraidly⁵, Laily Nissa Atul Mualifah^{6*}, Adelia Putri Pangestika⁷

^{1,2,3,4,5,6,7} Program Studi Statistika dan Sains Data, IPB University

*e-mail: lailayatul@apps.ipb.ac.id

DOI: 10.14710/j.gauss.14.2.314-324

Article Info:

Received: 2025-04-16

Accepted: 2025-09-12

Available Online: 2025-09-17

Keywords:

ARIMA-GARCH; Kastoba Lake;
LSTM

Abstract: Kastoba Lake, located on Bawean Island, East Java, is a unique natural tourist destination with significant potential for further development. To enhance strategic tourism management, predicting tourist visit numbers is necessary. This study aims to assess the performance of the ARIMA-GARCH and Long Short-Term Memory (LSTM) models in predicting daily tourist arrivals to Kastoba Lake, based on data collected between March 2023 and July 2024. These two methods were specifically selected because the dataset exhibits nonlinear patterns and heterogeneous variance. The ARIMA-GARCH model was employed to handle heteroscedasticity within the data, while LSTM was chosen for its ability to effectively learn and represent long-term patterns. The findings indicate that both models deliver comparable performance and are highly capable of identifying the underlying data trends. Moreover, each model is effective in forecasting short-term tourist visits, particularly over a 7-day horizon (one week). Consequently, these models are reliable tools for predicting and analyzing tourism trends at Kastoba Lake.

1. PENDAHULUAN

Peramalan deret waktu adalah teknik untuk memahami pola data yang dianalisis secara berkala dalam rentang waktu tertentu. Model yang umum digunakan untuk memodelkan dan meramalkan data historis adalah *Autoregressive Integrated Moving Average* (ARIMA). Namun, model ARIMA memiliki kendala ketika asumsi kehomogenan ragam terlanggar atau variansi data tidak konstan. Untuk mengatasi masalah ketidakhomogenan tersebut, model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) diperlukan (Mualifah, Soleh and Notodiputro, 2024). Namun, pemodelan ARIMA-GARCH terkadang tidak dapat memodelkan data secara akurat, sehingga diperlukan metode yang mampu menangkap pola-pola yang ada dalam data dengan lebih baik. Salah satu metode yang dapat digunakan untuk menghasilkan model yang lebih akurat adalah *Long Short-Term Memory* (LSTM). LSTM adalah metode peramalan yang diakui secara luas karena kemampuannya untuk membuat model prediktif yang andal (Rizkillah and Widiyanesti, 2022).

Metode peramalan dapat digunakan dalam berbagai bidang, salah satunya pariwisata. Dalam beberapa dekade terakhir, pariwisata telah menjadi salah satu industri paling diminati di dunia (Suban, Madhan and Shagirbasha, 2023). Danau Kastoba merupakan destinasi wisata menarik yang berlokasi di kawasan cagar alam hutan Pulau Bawean, yang berada di wilayah administratif Kabupaten Gresik, Jawa Timur. Keputusan dan strategi yang tepat harus digunakan untuk mengembangkan sektor pariwisata tersebut. Pemodelan dan peramalan adalah salah satu strategi yang berguna untuk pengembangan pariwisata. Hasil yang diperoleh dari pemodelan dapat digunakan untuk meramalkan jumlah pengunjung yang akan datang ke suatu industri pariwisata sehingga para pengelola dapat membuat perencanaan yang lebih baik tentang penggunaan sumber daya, pemasaran, dan

pengembangan infrastruktur untuk meningkatkan efektivitas rencana mereka untuk menarik wisatawan.

Beberapa studi sebelumnya telah menunjukkan bahwa metode peramalan deret waktu banyak digunakan dalam industri pariwisata. Misalnya, metode LSTM digunakan untuk meramalkan jumlah pengunjung ke Toraja Utara (Saladan *et al.*, 2023). Selain itu, metode ini digunakan untuk memprediksi pola kunjungan wisatawan mancanegara dan untuk menganalisis ulasan Tripadvisor di Jakarta dengan menambahkan pemodelan *Latent Dirichlet Allocation* (LDA) (Fahira and Prianto, 2023). Selain itu, metode LSTM juga digunakan untuk meramalkan jumlah pengunjung ke Bali (Sugiartawan, Permana and Prakoso, 2018). Selain metode LSTM, penambahan metode GARCH juga digunakan pada penelitian terdahulu dalam memprediksi jumlah penumpang kereta api di Jabodetabek pada tahun 2021 (Garini and Anbiya, 2022).

Penelitian ini bertujuan untuk memodelkan banyaknya wisatawan yang datang ke Danau Kastoba dengan menggunakan dua pendekatan model, ARIMA-GARCH dan LSTM. Perbandingan kedua model ini bermanfaat untuk menemukan model yang memiliki tingkat akurasi tinggi dan efisien untuk meramalkan jumlah wisatawan yang akan datang ke Danau Kastoba guna membantu meningkatkan perencanaan dan pengelolaan pariwisata.

2. TINJAUAN PUSTAKA

Model *Autoregressive Integrated Moving Average* (ARIMA) adalah metode peramalan yang khusus digunakan untuk data-data historis yang terurut. Komponen *Autoregressive* (AR) memperhitungkan hubungan antara nilai data pada periode tertentu dengan nilai data pada periode-periode sebelumnya, dan komponen *Moving Average* (MA) mengatasi fluktuasi yang disebabkan oleh faktor-faktor tak terduga (Chandra and Sarinem, 2015). Sedangkan komponen integrasi (I) berperan untuk menangani data yang memiliki tren (tidak stasioner) dengan menentukan jumlah pembedaan yang diperlukan untuk menghilangkan tren atau pola musiman agar bersifat stasioner (Rusminto, Wibowo and Wahyuni, 2024). Model ARIMA secara umum dapat dituliskan seperti pada Persamaan 1.

$$\phi_p(B)(1-B)^d Z_t = \theta_0 \theta_q(B) \alpha_t \quad (1)$$

dengan, $\phi_p(B) = 1(\phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$, $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p, 1 - B)^d$ adalah pembedaan (*differencing*) reguler ordo d serta α_t adalah sisaan.

Pada pemodelan ARIMA, ordo dari masing-masing komponen AR dan MA dapat ditentukan berdasarkan plot *Autocorrelation Function* (ACF), *Partial Autocorrelation Function* (PACF) atau *Extended Autocorrelation Function* (EACF). Sementara ordo untuk komponen integrasi (I) dipilih berdasarkan jumlah transformasi pembedaan (*differencing*) hingga diperoleh deret yang stasioner dalam nilaitengah (Notodiputro, Angraini, and Mualifah, 2025). Selain kestasioneran dalam nilaitengah, model ARIMA juga mensyaratkan data yang stasioner dalam ragam atau memiliki ragam yang homogen.

Model *Autoregressive Integrated Conditional Heteroscedasticity* (ARCH) dan *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) dapat digunakan untuk menangani masalah ragam tidak homogen pada data deret waktu (Raneo and Muthia, 2018). Model ARCH memiliki batasan, yaitu jumlah urutan yang dapat digunakan. Semakin banyak urutan yang dapat digunakan, semakin tidak layak untuk diterapkan. Persamaan 2 dapat digunakan untuk menulis persamaan model ARCH.

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


dengan σ_t^2 adalah penduga nilai ragam waktu ke- t , α_0 adalah konstanta, α_p adalah koefisien ARCH, e_{t-p}^2 adalah sisaan pada waktu $t-p$, serta p adalah ordo model ARCH.

Bollerslev (1986) memperluas teori tersebut dengan mengembangkan model yang memiliki struktur *lag* yang lebih fleksibel, yang disebut dengan GARCH (Sunarti, Mariani and Sugiman, 2016). Persamaan model GARCH dapat dituliskan melalui Persamaan 3.

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_p e_{t-p}^2 + \lambda_1 \sigma_{t-1}^2 + \dots + \lambda_q \sigma_{t-q}^2 \quad (3)$$

dengan σ_t^2 adalah penduga nilai ragam waktu ke- t , α_0 adalah suatu konstanta, α_p adalah koefisien dari komponen ARCH, λ_q adalah koefisien komponen GARCH, e_{t-p}^2 adalah sisaan pada waktu $t-p$, serta p, q merupakan ordo GARCH.

Model lain yang sering digunakan untuk melakukan peramalan data historis dengan pendekatan kecerdasan buatan adalah model *Long Short-Term Memory* (LSTM), yaitu variasi dari arsitektur jaringan saraf tiruan berulang (*Recurrent Neural Network/ RNN*) yang dilengkapi dengan sel memori yang berfungsi untuk menampung informasi dalam jangka waktu yang panjang. LSTM mampu menangani keterbatasan RNN dalam mempelajari ketergantungan jangka panjang yang melibatkan banyak langkah (Hanif, Sasongko and Laksito, 2023) dan masalah *vanishing gradient* yang sering terjadi pada RNN saat memproses data sekuensial dengan durasi yang cukup lama (Pontoh *et al.*, 2022). Dengan tiga gerbang utama, yaitu *input gate*, *forget gate* dan *output gate*, LSTM berkonsentrasi pada mekanisme pengelolaan memori. Gambar 1 menunjukkan struktur LSTM.



Gambar 1. Arsitektur LSTM

Pada LSTM, setiap *gate* memiliki fungsi input x_t dan *hidden state* sebelumnya yaitu h_{t-1} . Proses pertama *forget gate* menggunakan fungsi aktivasi *sigmoid* σ , untuk mengidentifikasi bagian sebelumnya dari *cell state* C_{t-1} yang akan dilupakan menurut Persamaan 4. Selanjutnya, pada *input gate* dihitung nilai aktivasi menggunakan fungsi *sigmoid* menurut Persamaan 5 untuk mengidentifikasi informasi baru yang akan ditambahkan ke *cell state*. Dalam proses ini, fungsi aktivasi *tanh* digunakan untuk menghasilkan kandidat *cell state* baru, yaitu $\hat{C}_t$ sesuai Persamaan 6. Setelah *cell state* diperbarui dengan menggabungkan *cell state* sebelumnya yang dipertahankan *forget gate* dan informasi baru yang dipilih *input gate* sesuai Persamaan 7 (Mualifah, Soleh and Notodiputro, 2024).

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (5)$$

$$\hat{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (6)$$

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (7)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t * \tanh(C_t) \quad (9)$$

Menurut Persamaan 8, bagian *cell state* baru C_t diidentifikasi pada *output gate* melalui fungsi aktivasi *sigmoid* untuk menghasilkan *hidden state*. Nilai *hidden state* kemudian dihasilkan dengan kombinasi *cell state* baru yang diaktifkan dengan fungsi *tanh* dikalikan dengan *output* dari *output gate* sesuai dengan Persamaan 9. Untuk mengurangi *overfitting*,

dropout ditambahkan pada jaringan LSTM dengan cara mematikan beberapa simpul (*neuron*) dan bobot yang menghubungkan simpul-simpul tersebut (Verianto, 2024).

Evaluasi performa model merupakan tahapan yang penting dilakukan dalam proses pemodelan data. Hal ini bertujuan untuk mengetahui performa model dalam meramalkan data pada periode berikutnya. Salah satu metrik evaluasi yang dapat digunakan untuk mengakses performa model adalah *Mean Absolute Percentage Error* (MAPE). Metrik MAPE menghitung persentase rata-rata dari selisih absolut antara nilai prediksi dan nilai aktual, sehingga dapat digunakan untuk melihat keakuratan model dalam meramalkan nilai aktual data (Verianto, 2024). Nilai MAPE dapat dihitung melalui Persamaan 10.

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|}{n} \times 100\% \quad (10)$$

3. METODE PENELITIAN

Data yang digunakan berasal dari publikasi <https://dakuwison.gresikkab.go.id/>, berupa data jumlah kunjungan harian wisatawan Nusantara ke Danau Kastoba dari 20 Maret 2023 hingga 31 Juli 2024. *Software* R dan Python digunakan untuk menganalisis data periode harian tersebut. Didasarkan pada pola, data yang dikumpulkan dibagi menjadi empat ratus data sebagai data latih dan seratus data sebagai data uji.

Proses analisis menggunakan model ARIMA terbagi menjadi beberapa tahapan yang dijelaskan sebagai berikut:

1. Eksplorasi data. Tahap awal sebelum pemodelan adalah melakukan visualisasi data deret waktu menggunakan plot *time series* untuk memahami pola umum seperti tren dan musiman.
2. Uji Kestasioneran Data. Terdapat dua kestasioneran yang harus terpenuhi dalam model ARIMA, yaitu kestasioneran dalam rata-rata yang diperiksa menggunakan plot *Autocorrelation Function* (ACF) dan kestasioneran dalam ragam yang dicek berdasarkan uji Box-Cox. Pelanggaran kestasioneran dalam rata-rata ditangani menggunakan pembedaan (*differencing*), sementara pelanggaran kestasioneran dalam ragam ditangani dengan transformasi Box-Cox. Beberapa jenis transformasi Box-Cox berdasarkan nilai λ optimum adalah sebagai berikut (Notodiputro, Angraini, and Mualifah, 2025):


Tabel 1. Beberapa transformasi box-cox	
λ	Transformasi
-1.0	$1/Y_t$
0.5	$1/\sqrt{Y_t}$
0.0	$\ln Y_t$
0.5	$\sqrt{Y_t}$
1.0	Tidak ditransformasi

3. Identifikasi model tentatif ARIMA. Identifikasi model potensial dilakukan berdasarkan pola dari plot ACF, *Partial Autocorrelation Function* (PACF) serta *Extended Autocorrelation Function* (EACF) untuk penentuan ordo p dan q dalam model ARIMA yang tercantum dalam Persamaan (1).
4. Pendugaan parameter dan seleksi model ARIMA. Pada masing-masing model tentatif, dilakukan pendugaan parameter model berdasarkan metode kemungkinan maksimum (*maximum likelihood method*). Selanjutnya, model terpilih ditentukan berdasarkan signifikansi parameter serta model dengan nilai AIC paling kecil.

5. Diagnostik sisaan. Model yang terpilih dilakukan uji diagnostik sisaan berupa pengecekan asumsi model yang meliputi kenormalan, kehomogenan ragam, kebebasan, dan nilai tengah dari sisaan model. Tahap diagnostik sisaan juga meliputi tahapan *overfitting*, yaitu menambah ordo dari model terpilih.
6. Penanganan Heteroskedastisitas. Jika dalam uji diagnostik sisaan terjadi pelanggaran asumsi homogenitas ragam, penambahan efek ARCH/GARCH diperlukan. Tahap awal pemodelan ARCH atau GARCH adalah melakukan uji LM ARCH pada sisaan model ARIMA terpilih guna menentukan efek ARCH atau GARCH yang tepat. Penentuan ordo p dan q pada Persamaan (2) dan (3) dilakukan berdasarkan plot ACF dari kuadrat sisaan. Selanjutnya, pendugaan dan pengujian signifikansi parameter dari model ARCH/GARCH dilakukan untuk memilih model terbaik. Penentuan model terbaik juga didasarkan pada nilai AIC.
7. Validasi model akhir menggunakan nilai MAPE berdasarkan Persamaan (10).
Sementara proses analisis menggunakan model LSTM adalah sebagai berikut:
 1. Normalisasi data. Untuk memulai pemodelan LSTM, teknik *min-max scaler* digunakan untuk menormalisasi data dalam rentang $[0, 1]$. Tahapan ini bertujuan agar skala data sesuai dengan fungsi-fungsi yang ada dalam jaringan LSTM.
 2. Spesifikasi dan tuning *hyperparameter* LSTM. Beberapa *hyperparameter* yang dispesifikasikan dan dituning pada proses pemodelan LSTM adalah *Neurons*, *Epoch*, *Patience*, *Batch size*, *Optimizer*, *Time steps*, *Loss function* (lihat Tabel 6).
 3. Pelatihan (*training*) jaringan LSTM. Model LSTM dioptimalkan menggunakan metode *Adaptive Moment Gradient* (ADAM) dengan *loss function* menggunakan *Root Mean Squared Error* (RMSE). Proses dalam pemodelan LSTM mengikuti Persamaan (4) sampai (9).
 4. Prediksi dan denormalisasi data. Tahapan ini dilakukan setelah pembentukan model, yaitu melakukan peramalan data kunjungan wisatawan untuk beberapa periode waktu ke depan dengan proses *one step ahead prediction*. Setelah memperoleh hasil peramalan, selanjutnya dilakukan transformasi balik data ke dalam skala asli data.
 5. Evaluasi model. Nilai MAPE yang dihitung berdasarkan Persamaan (10) digunakan untuk validasi model yang terbentuk.


4. HASIL DAN PEMBAHASAN

Data kunjungan wisawatawan dieksplorasi melalui plot deret waktu. Seperti yang ditunjukkan pada Gambar 2, data latih dan uji dibagi berdasarkan pola data. Data latih digunakan dari 20 Maret 2023 hingga 22 April 2024, dan data uji digunakan dari 23 April 2023 hingga 31 Juli 2024. Selanjutnya, pembagian data ini digunakan untuk pemodelan dan validasi model yang terbentuk. Menurut plot deret waktu, data cenderung bergerak dalam satu nilai tertentu yang terkumpul di bagian bawah, yaitu kurang dari 50 kunjungan wisatawan setiap harinya, yang menunjukkan bahwa kunjungan ke Danau Kastoba relatif rendah selama periode tersebut. Gambar 2 juga menunjukkan bahwa terdapat fluktuasi jumlah kunjungan yang cenderung berbeda sepanjang periode, misalkan pada periode 26 April 2023 dan 20 – 21 Januari 2024 terdapat lonjakan jumlah kunjungan wisatawan hingga melebihi 300 wisatawan. Selain itu, kunjungan wisatawan lebih tinggi pada akhir pekan.




Gambar 2. Plot deret waktu kunjungan wisatawan Danau Kastoba

Selanjutnya plot ACF dan plot Box-Cox digunakan untuk mengeksplorasi kestasioneran data dalam rata-rata dan ragam. Plot ACF yang ditunjukkan pada Gambar 3a, cenderung membentuk pola *tails off*, menunjukkan bahwa data stasioner dalam rata-rata. Namun, pada Gambar 3b, nilai λ sama dengan 1 tidak masuk dalam selang kepercayaan yang menunjukkan bahwa data tidak stasioner dalam ragam (Putri and Arliani, 2022). Kondisi ini memerlukan penanganan dengan transformasi Box-Cox.



Gambar 3. Plot ACF (a), Box-Cox (b) dan ACF setelah transformasi (c)

Setelah transformasi Box-Cox tampak bahwa nilai autokorelasi pada data cenderung menurun dengan lambat atau dikatakan berpola *tails off* (dapat dilihat dari plot ACF pada Gambar 3c). Pola ini merupakan ciri dari adanya pelanggaran kestasioneran dalam rata-rata, meskipun data telah dilakukan transformasi (Putri and Arliani, 2022). Penanganan kondisi ini dilakukan dengan pembedaan (*differencing*) sebanyak sekali pada data yang telah dilakukan transformasi Box-Cox.



Gambar 4. Plot ACF (a), PACF (b) dan EACF (c) setelah *differencing*

Setelah proses pembedaan terlihat bahwa plot ACF sudah *cuts off* yang menandakan bahwa ketidakstasioneran telah tertangani. Setelah data stasioner, proses penentuan model beserta ordonya dilakukan menggunakan bantuan plot ACF dan PACF. Berdasarkan gambar 4a terlihat ACF *cuts off* pada lag 1, sementara plot PACF (Gambar 4b) cenderung *tails off*, sehingga didapatkan model potensial pertama yaitu ARIMA(0,1,1). Jika melihat plot EACF (Gambar 4c), beberapa model potensial lainnya adalah ARIMA(0,1,2), ARIMA(1,1,1) dan ARIMA(1,1,2). Hasil identifikasi model secara lengkap disajikan pada Tabel 2.

Tabel 2. Hasil identifikasi model potensial

Model	Parameter	AIC
ARIMA(0,1,1)	Semua parameter signifikan	1084,60
ARIMA(0,1,2)	Semua parameter signifikan	1074,65
ARIMA(1,1,1)	Semua parameter signifikan	1070,89
ARIMA(1,1,2)	Semua parameter signifikan	1063,24
<i>Overfitting</i>		
ARIMA(1,1,3)	Tidak signifikan pada MA(3)	1063,07
ARIMA(2,1,2)	Semua parameter signifikan	1062,50

*signifikan pada taraf nyata 5%

Hasil Tabel 2 menunjukkan bahwa dari empat model potensial yang terpilih, model ARIMA(1,1,2) dianggap sebagai model terbaik berdasarkan nilai AIC. Untuk melihat model potensial lainnya, *overfitting* dilakukan dengan model ARIMA(1,1,3) dan ARIMA(2,1,2). Berdasarkan kriteria pemilihan model, model ARIMA(2,1,2) dianggap sebagai model terbaik. Selanjutnya, diagnostik sisaan dilakukan pada model ARIMA(2,1,2) untuk mengidentifikasi asumsi sisaan model.

Tabel 3. Hasil uji formal diagnostik sisaan

Uji	P-value	Kesimpulan
<i>Kolmogorv-Smirnov</i>	$2,2 \times 10^{-16}$	Sisaan tidak menyebar normal
<i>Ljung-Box</i> dari sisaan	0,5988	Sisaan saling bebas
<i>Ljung-Box</i> dari sisaan kuadrat	0,0494	Sisaan tidak homogen
<i>One-sample T test</i>	0,3419	Nilai tengah sisaan sama dengan nol

*signifikan pada taraf nyata 5%

Hasil uji formal menunjukkan bahwa asumsi kenormalan dan kehomogenan tidak terpenuhi, yang terlihat pada Tabel 3. Teorema limit pusat memungkinkan data dengan panjang 500 periode berdistribusi normal, sehingga pelanggaran asumsi normalitas dapat diabaikan (Desvina and Meijer, 2018). Pada asumsi homogenitas sisaan, nilai *p-value* hanya sedikit berbeda dengan taraf nyata, yang menimbulkan keraguan terkait pemenuhan asumsi tersebut. Untuk memastikan hal ini, dilakukan uji LM ARCH. Heteroskedastisitas terdeteksi jika *p-value* hasil pengujian lebih kecil dari taraf nyata 5%. Apabila hasil uji menunjukkan adanya pelanggaran asumsi kehomogenan ragam, maka perlu penambahan efek ARCH/GARCH untuk menangani pola ketidakpastian data. Hasil pengujian ARCH-LM dapat dilihat pada Tabel 4.

Tabel 4. Hasil uji ARCH-LM

Lag	P-value	Lag	P-value
1	$2,697 \times 10^{-8*}$	11	$6,417 \times 10^{-7*}$
2	$7,174 \times 10^{-8*}$	12	$8,578 \times 10^{-7*}$
3	$1,472 \times 10^{-8*}$	13	$1,143 \times 10^{-6*}$
4	$3,664 \times 10^{-9*}$	14	$1,793 \times 10^{-6*}$
5	$1,077 \times 10^{-8*}$	15	$3,18 \times 10^{-6*}$


*signifikan pada taraf nyata 5%

Berdasarkan hasil *LM Test*, pengujian efek ARCH/GARCH yang signifikan pada lag 1–15 menunjukkan bahwa ada ketergantungan jangka panjang dalam data, sehingga penambahan efek GARCH lebih sesuai untuk digunakan dibandingkan ARCH (Desvina and Meijer, 2018). Hal ini menunjukkan variabilitas data tidak konstan dan dipengaruhi oleh volatilitas data sebelumnya dalam jangka waktu yang panjang. Untuk mendapatkan model terbaik dalam mengidentifikasi pola volatilitas dalam data, efek GARCH yang sesuai ditambahkan dengan proses *trial and error*.

Tabel 5. Estimasi parameter model GARCH

Model	Signifikansi Parameter	AIC	<i>P-value LM Test</i>
GARCH(1,1)	Semua parameter signifikan	2,4897	0,0836
GARCH(1,2)	Tidak signifikan pada β_1	2,4712	0,1285
GARCH(2,1)	Tidak signifikan pada μ , AR(1), AR(2), MA(1), MA(2)	2,5103	0,6434
GARCH(2,2)	Tidak signifikan pada ω , α_1 , α_2 , β_1 , β_2	2,4961	0,1341

Sesuai hasil yang ditunjukkan pada Tabel 5, GARCH(1,1) dianggap sebagai model terbaik berdasarkan pertimbangan signifikansi parameter dan nilai AIC terkecil. Model ini berhasil menghilangkan efek heteroskedastisitas yang ditunjukkan oleh *p-value* yang dihasilkan pada *LM Test*.



Gambar 5. Hasil prediksi ARIMA-GARCH

Model ARIMA(2,1,2)-GARCH(1,1) menjadi model terbaik untuk menjelaskan pola kunjungan wisatawan ke Danau Kastoba dengan menggabungkan model ARIMA dan GARCH terbaik. Seperti yang ditunjukkan pada Gambar 5, hasil prediksi model ARIMA(2,1,2)-GARCH(1,1) menghasilkan nilai MAPE data latih sebesar 0,6%. Hasil ini menunjukkan bahwa model mampu menangkap pola data dengan baik, yang tercermin dari hasil prediksi yang sangat dekat dengan data aslinya (Gambar 5), meskipun perlu diperhatikan bahwa pada saat terjadi lonjakan ekstrem model cenderung untuk memberikan prediksi di bawah nilai aslinya (*underestimate*).

Berdasarkan hasil pengepasan model terhadap data latih, selanjutnya dilakukan validasi model untuk mengukur kemampuan model dalam meramalkan data di masa depan. Peramalan dilakukan untuk beberapa rentang waktu, yaitu 7 hari, 30 hari, 60 hari, dan 100 hari. Pada periode peramalan 7 hari model menghasilkan nilai MAPE terendah, sebesar 13,44%. Hasil tersebut menunjukkan bahwa model ARIMA-GARCH memiliki performa yang baik dan cocok digunakan untuk peramalan jangka pendek, sebagaimana hasil yang ditunjukkan oleh Setyowibowo *et al* (2022). Sementara untuk peramalan jangka panjang, model ARIMA-GARCH menghasilkan peramalan yang jauh dari nilai asli data (Gambar 5).

Selanjutnya, untuk membangun model LSTM, diperlukan penentuan kombinasi *hyperparameter* yang optimal, yang mana pada studi ini proses penentuan *hyperparameter* dilakukan melalui *trial and error* (Witanto *et al.*, 2022). Proses ini bertujuan untuk meningkatkan kinerja model dengan menyesuaikan kombinasi *hyperparameter* pada algoritma LSTM, yang mencakup jumlah *neuron* per *layer*, *epoch*, dan *batch size* (Ananda *et al.*, 2023). Karakteristik model yang tercantum pada Tabel 6 adalah dasar untuk pemodelan yang dilakukan.


Berdasarkan karakteristik yang ditunjukkan pada Tabel 6, model dibangun berdasarkan lima lapisan (*layer*) yang terdiri dari lapisan *LSTM1*, *dropout*, *LSTM2*, *dropout* dan *dense*. Lapisan LSTM menggunakan fungsi aktivasi *tanh* untuk memetakan *output* dalam rentang nilai -1 hingga 1 (Kurniawan, Ceasaro and Sucipto, 2024). Fungsi aktivasi digunakan untuk membantu menormalisasi *output* setiap lapisan sehingga mendukung stabilitas dan

konvergensi model selama proses pelatihan. *Dropout* sebesar 0,1 bermakna menonaktifkan 10% simpul (*neuron*) atau bobot untuk simpul tersebut bernilai nol.

Tabel 6. Karakteristik model LSTM

Parameter	Jumlah
<i>Neurons</i>	30, 50, 70
<i>Epoch</i>	20, 50, 100
<i>Patience</i>	30
<i>Batch size</i>	20, 50, 80
<i>Optimizer</i>	ADAM
<i>Time steps</i>	1
<i>Loss function</i>	RMSE

Nilai *epoch* adalah jumlah iterasi yang dilakukan model selama proses pembelajaran (Dzaky, 2021). Selama proses pembelajaran data, data latih dibagi menjadi beberapa nilai *batch* untuk setiap kelompok. Setelah setiap *batch* diproses, *optimizer* ADAM digunakan untuk mengoptimalkan algoritma. Dengan *learning rate* 0,001 dan *loss function* RMSE, *optimizer* ini mampu menangani *sparse gradient* pada *noisy problem* (Salsabila et al., 2022).



Gambar 6. Hasil prediksi LSTM

Berdasarkan proses *tuning hyperparameter* yang dilakukan didapatkan model terbaik dengan kombinasi *hyperparameter* jumlah *neuron* per lapisan sebanyak 50 *neuron*, *epoch* sebanyak 100 serta *batch size* yang digunakan sebanyak 80. Kombinasi ini memberikan performa prediksi yang sangat baik dengan nilai MAPE sebesar 0,57% pada data latih. Nilai MAPE yang sangat rendah ini menunjukkan bahwa model memiliki kemampuan yang tinggi dalam mengenali pola historis data dan menghasilkan prediksi yang sangat mendekati nilai aktual seperti pada Gambar 6.

Model LSTM juga divalidasi terhadap data uji pada beberapa periode waktu yang sama dengan model ARIMA-GARCH. Validasi menghasilkan nilai MAPE sebesar 14% untuk peramalan 7 hari ke depan. Berbeda dengan model ARIMA-GARCH yang memberikan hasil prediksi dengan pola fluktuatif, model LSTM memberikan prediksi yang cenderung konstan di sekitaran nilai tertentu (Gambar 6).

Pada studi ini, nilai MAPE yang dihasilkan oleh model ARIMA-GARCH dan LSTM tidak berbeda jauh. Uji *paired t-test* terhadap galat (*error*) kedua model dilakukan untuk mengetahui apakah terdapat perbedaan performa yang signifikan antara kedua model. Hasil uji menunjukkan nilai *t* sebesar -0,1711 dengan *p-value* sebesar 0,8698. Nilai tersebut mengindikasikan bahwa secara statistika tidak ada perbedaan signifikan antara galat prediksi dari kedua model. Hasil ini menunjukkan bahwa kedua model memiliki performa yang sebanding dalam meramalkan jumlah kunjungan wisatawan ke Danau Kastoba. Dengan demikian, pengambil keputusan dapat menggunakan salah satu model sesuai kebutuhan praktis, misalnya mempertimbangkan kemudahan implementasi atau efisiensi komputasi, tanpa mengurangi akurasi prediksi.

5. KESIMPULAN

ARIMA-GARCH dan LSTM merupakan dua metode peramalan deret waktu yang memiliki kemampuan menangkap pola kompleks dalam data. Pada studi ini kedua model dievaluasi untuk memodelkan jumlah kunjungan wisatawan Danau Kastoba. Hasil studi menunjukkan model ARIMA-GARCH menghasilkan MAPE sebesar 0,6% (data latih) dan 13,44% (data uji), sementara model LSTM menghasilkan MAPE 0,57% (data latih) dan 14% (data uji). Secara statistika, kedua model memiliki performa yang tidak berbeda signifikan. Secara lebih detail, model ARIMA-GARCH dan LSTM dapat dijadikan sebagai model alternatif untuk meramalkan jumlah kunjungan wisatawan Danau Kastoba, utamanya peramalan untuk periode jangka pendek, misalnya 7 periode ke depan.

DAFTAR PUSTAKA

- Ananda, N., Wicaksana, H.S., Wijaya, Y.G., Hijazi, R. (2023) 'Hyperparameter Tuning Lstm Sebagai Estimator Sensor Relative Humidity Pada Automatic Weather Station Berbasis Simulated Annealing Hyperparameter Tuning Lstm As Relative Humidity Sensor Estimator on Automatic Weather Station Based on Simulated Annealing', *Januari*, 4(1), pp. 35–43.
- Chandra, N.E. dan Sarinem (2015) 'Kasus Virus Ebola Di Guinea Dengan Metode Arima', *Jurnal UJMC*, 2(November), pp. 28–35. Available at: <https://doi.org/https://doi.org/10.52166/ujmc.v2i1.447>.
- Desvina, A.P. dan Meijer, I.O. (2018) 'Penerapan Model ARCH/GARCH untuk Peramalan Nilai Tukar Petani', *Jurnal Sains Matematika dan Statistika*, 4(1), pp. 43–54.
- Dzaky, A.T.R. (2021) 'Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network', *e-Proceeding of Engineering*, 8(2), pp. 3039–3055. Available at: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/14701/14478>.
- Fahira, F. dan Prianto, C. (2023) 'Prediksi Pola Kedatangan Turis Mancanegara dan Menganalisis Ulasan Tripadvisor dengan LSTM dan LDA', *Jurnal Tekno Insentif*, 17(2), pp. 69–83. Available at: <https://doi.org/10.36787/jti.v17i2.1096>.
- Garini, F.C. dan Anbiya, W. (2022) 'Application of GARCH Forecasting Method in Predicting The Number of Rail Passengers (Thousands of People) in Jabodetabek Region', *Jurnal Matematika, Statistika dan Komputasi*, 18(2), pp. 198–223. Available at: <https://doi.org/10.20956/j.v18i2.18382>.
- Hanif, A.F., Sasongko T.B. dan Laksito, A.D. (2023) 'Perbandingan Kinerja LSTM, Bi-LSTM, dan GRU pada Klasifikasi Judul Berita Clickbait', *The Indonesian Journal of Computer Science*, 12(4), pp. 2136–2150. Available at: <https://doi.org/10.33022/ijcs.v12i4.3281>.
- Kurniawan, K., Ceasaro, B. dan Sucipto, S. (2024) 'Perbandingan Fungsi Aktivasi Untuk Meningkatkan Kinerja Model LSTM Dalam Prediksi Ketinggian Air Sungai', *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 10(1), pp. 134–143. Available at: <https://doi.org/10.26418/jp.v10i1.72866>.
- Mualifah, L.N.A., Soleh, A.M. dan Notodiputro, K.A. (2024) 'Comparison of GARCH, LSTM, and Hybrid GARCH-LSTM Models for Analyzing Data Volatility', *International Journal of Advances in Soft Computing and its Applications*, 16(2), pp. 150–165. Available at: <https://doi.org/10.15849/IJASCA.240730.10>.
- Notodiputro, K.A., Angraini, Y., Mualifah, L.N.A. (2025) 'Analisis Data Deret Waktu dengan Python Pendekatan Box-Jenkins dan Machine Learning', Bogor, IPB Press.
- Pontoh, R.S., Toharudin, T., Ruchjana, B.N., Gumelar, F., Putri, F.A., Agisya, M.N., Caraka, R.E.

- (2022) 'Jakarta Pandemic to Endemic Transition: Forecasting COVID-19 Using NNAR and LSTM', *Applied Sciences (Switzerland)*, 12(12). Available at: <https://doi.org/10.3390/app12125771>.
- Putri, S.M. dan Arliani, E. (2022) 'Peramalan produksi padi di Kabupaten Sleman menggunakan model arima forecasting rice production in Sleman Regency using the arima model', *Jurnal Kajian dan Terapan Matematika*, 8(3), pp. 188–198. Available at: <http://journal.student.uny.ac.id/ojs/index.php/jktm>.
- Raneo, A.P. dan Muthia, F. (2018) 'Penerapan Model GARCH Dalam Peramalan Volatilitas di Bursa Efek Indonesia', *Jurnal Manajemen dan Bisnis Sriwijaya*, 16(2018), pp. 194–202. Available at: <http://ejournal.unsri.ac.id/index.php/jmbs>.
- Rizkillah, M.F. dan Widiyanesti, S. (2022) 'Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)', *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(1), pp. 25–31. Available at: <https://doi.org/10.29207/resti.v6i1.3630>.
- Rusminto, M.Z., Wibowo, S.A. dan Wahyuni, F.S. (2024) 'Peramalan Harga Saham Menggunakan Metode Arima (Autoregressive Integrated Moving Average) Time Series', *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(2), pp. 1263–1270. Available at: <https://doi.org/10.36040/jati.v8i2.9089>.
- Saladan, F., Michael, A., Gallaran, F.B., Marchelin. (2023) 'Prediksi Jumlah Kunjungan Wisatawan Di Toraja Utara Menggunakan Metode Long Short Term Memory', *11 Infinity*, 3(1), pp. 2777–0451. Available at: <https://doi.org/10.47178/infinity.v3i1.2189>.
- Salsabila, F., Fatharani, R.A., Taqiyyudin, T.A., Rizki, M.I. (2022) 'Aplikasi Model ARCH/GARCH dalam Peramalan Laju Inflasi Bulanan Indonesia', *Jurnal Sains Matematika dan Statistika*, 8(1), pp. 34–45. Available at: <https://doi.org/10.24014/jsms.v8i1.13252>.
- Setyowibowo, S., As'ad, M., Sujito, Farida, E. (2022) 'Forecasting of Daily Gold Price using ARIMA-GARCH Hybrid Model', *Jurnal Ekonomi Pembangunan*, 19(2), pp. 257–270. Available at: <https://doi.org/10.29259/jep.v19i2.13903>.
- Suban, S.A., Madhan, K. dan Shagirbasha, S. (2023) 'A bibliometric analysis of Halal and Islamic tourism', *International Hospitality Review*, 37(2), pp. 219–242. Available at: <https://doi.org/10.1108/ihr-05-2021-0038>.
- Sugiartawan, P., Permana, A.A.J., dan Prakoso, P.I. (2018) 'Forecasting Kunjungan Wisatawan Dengan Long Short Term Memory (LSTM)', *Jurnal Sistem Informasi dan Komputer Terapan Indonesia (JSIKTI)*, 1(1), pp. 43–52. Available at: <https://doi.org/10.33173/jsikti.5>.
- Sunarti, Mariani, S. dan Sugiman (2016) 'Perbandingan Akurasi Model ARCH dan GARCH pada Peramalan Harga Saham Berbantuan MATLAB', *UNNES Journal of Mathematics*, 3(2), pp. 4–7. Available at: <http://journal.unnes.ac.id/sju/index.php/ujme>.
- Verianto, E. (2024) 'Penerapan LSTM dengan regularisasi untuk mencegah overfitting pada model prediksi tingkat inflasi di Indonesia', *Jurnal Sistem Informasi dan Sistem Komputer*, 9(2), pp. 195–204. Available at: <https://doi.org/10.51717/simkom.v9i2.460>.
- Witanto, K.S., Sanjaya, ER., Karyawati, A.E., Kadyanan, I.A.G.A., Suhartana, I.K.G., Astuti, L.G. (2022) 'Implementasi LSTM Pada Analisis Sentimen Review Film Menggunakan Adam Dan RMSprop Optimizer', *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, 10(4), p. 351. Available at: <https://doi.org/10.24843/jlk.2022.v10.i04.p05>.