

Prediksi Kunjungan Wisatawan Mancanegara Ke Indonesia Berdasarkan Pintu Masuk Menggunakan Metode *Long Short-Term Memory* (LSTM)

Wiam¹, Miftahul Walid², Aang Kisnu Darmawan³

¹Teknik Informatika, Teknik, Universitas Islam Madura

²Teknik Informatika, Teknik, Universitas Islam Madura

³Sistem Informasi, Teknik, Universitas Islam Madura

¹wiamwulandari10@gmail.com, ²miftahulwalid@gmail.com, ²aangkisnudarmawan@gmail.com

ABSTRAK

Pariwisata merupakan salah satu sektor penting yang mendukung perekonomian suatu negara, termasuk Indonesia. Prediksi jumlah kunjungan wisatawan mancanegara menjadi hal yang krusial untuk menunjang perencanaan dan pengambilan keputusan strategis dalam pengembangan sektor ini. Saat ini, belum banyak pendekatan prediktif yang memanfaatkan model deep learning untuk mengantisipasi dinamika jumlah kunjungan wisatawan berdasarkan kategori pintu masuk ke Indonesia. Penelitian ini bertujuan dua hal: pertama menerapkan metode Long Short-Term Memory (LSTM) dalam memprediksi kunjungan wisatawan mancanegara ke Indonesia berdasarkan tiga jenis pintu masuk, yaitu udara, laut, dan darat. Kedua, mengukur tingkat akurasi dari hasil prediksi yang dihasilkan. Dataset yang digunakan berupa data bulanan kunjungan wisatawan mancanegara menurut pintu masuk kedatangan dari Januari 2008 hingga Desember 2024 yang diperoleh dari Badan Pusat Statistik (BPS). Model LSTM dilatih menggunakan dua lapisan LSTM dengan masing-masing 64 neuron serta dropout sebesar 0,1. Evaluasi model dilakukan menggunakan metrik RMSE, MAE, MAPE, dan R². Hasil evaluasi terbaik pada masing-masing kategori pintu masuk menunjukkan bahwa pintu udara memiliki nilai RMSE 73.133,52, MAE 57.747,22, MAPE 17,56%, dan R² sebesar 0,9405. Untuk pintu laut, diperoleh nilai RMSE 37.267,33, MAE 28.368,17, MAPE 15,44%, dan R² sebesar 0,7542. Sementara itu, pintu darat diperoleh nilai RMSE 13.871,17, MAE 9.511,75, MAPE 12,51%, dan R² sebesar 0,3728. Hasil prediksi menunjukkan bahwa pintu udara dan laut menunjukkan kecenderungan peningkatan dalam 12 bulan ke depan, sedangkan pintu darat justru mengalami penurunan. Secara keseluruhan, metode LSTM menunjukkan kinerja yang baik dalam memodelkan tren data kunjungan wisatawan mancanegara berdasarkan pola data historis dan berpotensi menjadi alat bantu dalam pengambilan keputusan strategis di sektor pariwisata

Kata kunci: *Prediksi, Kunjungan Wisatawan Mancanegara, Metode Long Short Term Memory (LSTM), Deep Learning.*

ABSTRACT

Tourism is one of the key sectors that supports a country's economy, including Indonesia. Predicting the number of international tourist arrivals is crucial for supporting planning and strategic decision-making in the development of this sector. Currently, there are still few predictive approaches that utilize deep learning models to anticipate the dynamics of tourist arrivals based on the type of entry point into Indonesia. This study has two main objectives: first, to apply the Long Short-Term Memory (LSTM) method to predict international tourist arrivals to Indonesia based on three types of entry points—air, sea, and land. Second, to measure the accuracy of the resulting predictions. The dataset used consists of monthly data on international tourist arrivals by point of entry from January 2008 to December 2024, obtained from the Central Bureau of Statistics (BPS). The LSTM model was trained using two LSTM layers with 64 neurons each and a dropout rate of 0.1. Model evaluation was carried out using RMSE, MAE, MAPE, and

R² metrics. The best evaluation results for each entry point category show that the air entry point has an RMSE of 73,133.52, MAE of 57,747.22, MAPE of 17.56%, and R² of 0.9405. For the sea entry point, the RMSE is 37,267.33, MAE is 28,368.17, MAPE is 15.44%, and R² is 0.7542. Meanwhile, the land entry point recorded an RMSE of 13,871.17, MAE of 9,511.75, MAPE of 12.51%, and R² of 0.3728. The prediction results indicate an upward trend for air and sea entry points over the next 12 months, while the land entry point is expected to experience a decline. Overall, the LSTM method demonstrates strong performance in modeling the trend of international tourist arrival data based on historical patterns and has the potential to serve as a valuable tool for strategic decision-making in the tourism sector.

Keywords Prediction, Foreign Tourist Visits, Long Short Term Memory (LSTM) Method, Deep Learning

1. PENDAHULUAN

Pariwisata merupakan salah satu sektor penting yang berkontribusi terhadap perekonomian suatu negara, termasuk Indonesia [1]. Sebagai negara kepulauan dengan beragam destinasi wisata unggulan, Indonesia menarik banyak wisatawan mancanegara setiap tahunnya [2]. Oleh karena itu, sektor pariwisata memerlukan perhatian serius dalam pengembangannya, termasuk investasi besar dalam infrastruktur, transportasi, fasilitas akomodasi, dan sarana rekreasi [3]. Mengingat bahwa sektor pariwisata merupakan salah satu sumber devisa negara yang penting, pengembangannya memerlukan investasi besar di berbagai aspek [4]. Untuk itu, prediksi jumlah kunjungan wisatawan mancanegara menjadi hal yang penting, khususnya berdasarkan pintu masuk kedatangannya. Informasi ini dapat membantu pemangku kebijakan dalam mengelola arus wisatawan secara lebih efektif, merencanakan kebutuhan fasilitas di titik kedatangan, serta menyusun strategi promosi yang lebih tepat sasaran dan agar dapat mempermudah perencanaan dan pengelolaan destinasi wisata. Salah satu cara dalam melakukan antisipasi tersebut dapat dilakukan dengan prediksi untuk periode di masa yang akan datang [5].

Prediksi atau *Forecasting* adalah suatu usaha dalam memperkirakan kejadian pada masa yang akan datang dengan cara melakukan suatu pengujian pada masa lalu dengan menggunakan data dalam bentuk mingguan, bulanan atau

triwulan dengan memperhatikan suatu nilai berupa data di masa lalu dan data saat ini [6]. Metode *forecasting* yang umum digunakan adalah data deret waktu atau *time series* [7]. *Time Series* atau deret waktu adalah rangkaian nilai-nilai suatu variabel yang dicatat dalam jangka waktu berurutan menggunakan analisa pola hubungan antar variabel yang diperkirakan dan variabel waktu [8]. Salah satu metode yang dapat digunakan untuk memodelkan dan memprediksi data deret waktu (*time series*) adalah *Long Short-Term Memory* (LSTM) [9]. *Long Short-Term Memory* (LSTM) merupakan sebuah arsitektur *Recurrent Neural Network* (RNN) yang memiliki *memory cell*, yang dirancang untuk menangani data deret waktu dengan dengan pola non linear. Dengan *memory cell*, arsitektur LSTM dapat bekerja lebih baik dalam menyimpan informasi jangka panjang, sehingga lebih efektif dalam memproses data sekuensial yang panjang terutama pada pengolahan data yang bersifat *time series*. [10].

Penelitian sebelumnya pernah dilakukan oleh [11] yang Memprediksi Kunjungan Wisatawan Mancanegara Melalui Pintu Udara, hasil penelitian menunjukkan bahwa model ARIMA(1,1,0), (0,0,1) memberikan hasil evaluasi terbaik dengan nilai MAE sebesar 749030.4, MAPE sebesar 23196.45, MASE sebesar 17.86681, SMAPE sebesar 175.9592, dan RMSE sebesar 779670.7. Selanjutnya [12] melakukan penelitian mengenai Prediksi Jumlah Wisatawan Mancanegara Ke Sumatera Utara Berdasarkan Pintu Masuk Utama


Menggunakan Algoritma *Backpropagation Neural Network*, Penelitian ini melakukan beberapa pengujian dengan berbagai *learning rate* dan *epoch* untuk menentukan model terbaik. Hasil penelitian menunjukkan bahwa model dengan *learning rate* 0.0001 dan *epoch* 200 memberikan hasil terbaik dengan nilai MSE sebesar 4.4551. Sementara itu [13] melakukan penelitian mengenai Prediksi Jumlah Kedatangan Wisatawan Mancanegara Di Indonesia Berdasarkan Pintu Masuk Kedatangan, Hasilnya menunjukkan bahwa model XGBoost menghasilkan evaluasi terbaik dengan nilai RMSE sebesar 671935.2, MAE 648139.1, dan MAPE 20985.35. Namun demikian, metode tradisional yang digunakan dalam penelitian-penelitian sebelumnya memiliki keterbatasan dalam menangkap pola non-linear pada data deret waktu. Oleh karena itu, diperlukan pendekatan yang lebih canggih, seperti *Long Short-Term Memory* (LSTM), yang mampu menangani data sekuensial dalam jangka Panjang.

Berdasarkan permasalahan yang telah dijelaskan, Penelitian ini bertujuan untuk menerapkan algoritma *Long Short-Term Memory* (LSTM) dalam memprediksi kunjungan wisatawan mancanegara ke Indonesia berdasarkan pintu masuk kedatangannya yang berfokus pada tiga jenis pintu masuk utama yaitu pintu masuk udara, laut, dan darat, serta mengukur akurasi hasil prediksi yang dihasilkan, dengan harapan hasil prediksi tersebut dapat memberikan informasi yang akurat, dan dapat membantu dalam pengambilan keputusan strategis serta mendorong pertumbuhan sektor pariwisata di Indonesia.

2. METODOLOGI PENELITIAN

Metodologi penelitian ini mencakup tahapan-tahapan sistematis yang digunakan dalam membangun dan mengevaluasi model *Long Short-Term Memory* (LSTM) untuk memprediksi kunjungan wisatawan

mancanegara ke Indonesia berdasarkan kategori pintu masuk, yaitu udara, laut, dan darat. Model dikembangkan menggunakan bahasa pemrograman Python dan dijalankan pada platform Google Colab. Beberapa pustaka (library) yang digunakan dalam penelitian ini antara lain: NumPy, Pandas, Matplotlib, Scikit-learn, serta TensorFlow/Keras sebagai framework utama untuk membangun dan melatih model LSTM. Tahapan penelitian yang dilakukan dari awal hingga akhir dapat dilihat pada Gambar 1. Adapun langkah-langkahnya dijabarkan dalam bentuk flowchart sebagai berikut:



Gambar 1. Metodologi Penelitian

2.1 Pengumpulan Data

Pada penelitian ini, data yang digunakan merupakan dataset historis mengenai kunjungan wisatawan mancanegara ke Indonesia berdasarkan pintu masuk. Dataset tersebut diperoleh dari situs resmi Badan Pusat Statistik (BPS) <https://www.bps.go.id/>. Data yang digunakan mencakup jumlah kunjungan wisatawan mancanegara per bulan ke Indonesia menurut pintu masuk selama periode Januari 2008 hingga Desember 2024, dengan total sebanyak 204 data. Dataset yang diambil dalam

bentuk bulanan dan hanya berfokus pada tiga jenis pintu masuk utama, yaitu pintu masuk melalui udara, darat, dan darat.

2.2 Preprocessing Data

Pada tahap ini, data yang telah dikumpulkan diproses agar siap digunakan untuk membangun model. Langkah-langkah preprocessing meliputi pembersihan data untuk menghilangkan data yang tidak relevan atau outlier, Transformasi data untuk mengubah data ke format date time, normalisasi data untuk mengonversi nilai ke dalam rentang tertentu [0,1], Dalam penelitian ini, proses normalisasi dilakukan menggunakan metode Min-Max Scaler agar model LSTM dapat bekerja secara optimal. Adapun rumus untuk normalisasi data menggunakan Min-Max Scaler dapat dihitung dengan persamaan sebagai berikut:

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

2.3 Pembentukan Data Time Series

Dalam penelitian ini, dilakukan pembentukan dataset time series Pembentukan ini bertujuan untuk mengubah data deret waktu menjadi format yang sesuai bagi model Long Short-Term Memory (LSTM), yang memerlukan input dalam bentuk urutan data (sequence). Dan disini digunakan time_step sebesar 12, yang berarti model menggunakan 12 bulan sebelumnya untuk memprediksi bulan selanjutnya. Dataset akhir yang terbentuk memiliki format array 3 dimensi: [samples, timesteps, features], yang merupakan format input standar untuk model LSTM.

2.4 Pembagian Data

Pada tahap pembagian data, pada penelitian ini dataset dibagi menjadi dua bagian utama, yaitu data latih (training data) dan data uji (testing data) dengan perbandingan 80:20. 80% untuk data latih, dan 20% untuk data uji.


2.5 Training Data

Pada tahap pelatihan (training), model LSTM dilatih menggunakan data latih dengan konfigurasi parameter yang telah ditentukan, seperti inisialisasi parameter yang mencakup penentuan jumlah layer pada model LSTM, jumlah epoch, ukuran batch (batch size), serta time step yang akan digunakan dalam pembuatan model LSTM. Model dikonfigurasi menggunakan optimizer Adam dan loss function Mean Squared Error (MSE). Optimizer Adam dipilih karena kemampuannya menyesuaikan learning rate secara adaptif, mempercepat pelatihan dan meningkatkan kinerja model. Sementara itu, MSE digunakan karena sesuai untuk permasalahan prediksi atau regresi, dengan tujuan meminimalkan selisih antara nilai prediksi dan aktual. Setelah kompilasi, model memasuki tahap pelatihan/training, di mana model mempelajari pola data melalui iterasi sesuai jumlah epoch berapa kali model melihat seluruh dataset dan batch size jumlah sampel yang diproses sebelum pembaruan parameter. Pemilihan epoch dan batch size yang tepat penting untuk memastikan model belajar efektif tanpa overfitting atau underfitting.

2.6 Long Short Term Memory (LSTM)

Dalam penelitian ini, digunakan metode Long Short-Term Memory (LSTM) untuk mempelajari pola data deret waktu. LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) yang dikembangkan oleh Hochreiter dan Schmidhuber pada tahun 1997. Keunggulan utama LSTM adalah kemampuannya mengatasi masalah hilangnya gradien pada RNN saat memproses data sekuensial panjang, yang sering kali menyebabkan ketidakmampuan dalam menangkap pola jangka Panjang. LSTM dilengkapi dengan tiga gerbang utama input gate, forget gate, dan output gate yang berfungsi untuk mengatur informasi yang disimpan, dilupakan, atau dikeluarkan. Dengan

mekanisme ini, LSTM mampu mempertahankan informasi penting dari data sebelumnya dan memahami hubungan antar data dalam urutan waktu. Oleh karena itu, LSTM sangat efektif untuk menangani data time series yang memerlukan pemahaman terhadap konteks historis.



Gambar 2. Arsitektur LSTM

Pada Gambar 2. menunjukkan struktur lapisan tersembunyi pada arsitektur LSTM, yaitu *memory cell*. Memory cell berfungsi untuk menyimpan informasi, baik dalam jangka waktu pendek maupun Panjang. Berikut ini merupakan penjelasan mengenai gerbang-gerbang (*gate*) yang terdapat dalam satu unit *memory cell* pada LSTM. Secara matematis, mekanisme kerja dari setiap unit LSTM dijelaskan melalui persamaan-persamaan berikut:

1. Forget gate

$$f_t = \sigma(W_f \times x_t + W_f \times h_{t-1} + b_f) \quad (2)$$

Forget gate merupakan gerbang pertama dalam LSTM pada *forget gate* informasi yang tidak dibutuhkan akan dihilangkan menggunakan fungsi *sigmoid*, *forget gate* menerima h_{t-1} dan x_t untuk menghasilkan nilai 0 atau 1 pada $c_t - 1$ saat *forget gate* bernilai 1 maka informasi akan disimpan di dalam *cell state*, namun jika bernilai 0 maka informasi akan di buang.

2. Input Gate

$$i_t = \sigma(W_i \times x_t + W_i \times h_{t-1} + b_i) \quad (3)$$

Input gate merupakan informasi dipilih sebelum dibawa ke *cell state* menggunakan fungsi aktivasi sigmoid. Selain itu, kandidat vektor baru ditentukan menggunakan fungsi *tanh* yang dibawa ke dalam bagian *cell state*

3. Cell State

$$c_t = f_t \times c_{t-1} + i_t \times c_t \quad (4)$$

Cell state, nilai state lama c_{t-1} akan diperbarui ke nilai state baru c_t dengan mengalikan nilai *cell state* lama dengan f_t untuk menghapus nilai dari *forget gate* sebelumnya dan menambahkan *input gate* yang dikalikan dengan c_t sebagai nilai baru yang digunakan untuk memperbarui nilai *cell state*.

4. Output Gate

$$o_t = \sigma(W_o \times x_t + W_o \times h_{t-1} + b_o) \quad (5)$$

$$h_t = \tanh(c_t) \times o_t \quad (6)$$

Output gate merupakan gerbang terakhir LSTM yang menentukan keluaran keadaan sel, lapisan sigmoid menentukan bagian *cell state* yang akan dicetak Kemudian hasil keadaan sel diungkapkan ke lapisan *tanh* dan dikalikan dengan keluaran dari lapisan sigmoid.

2.7 Testing Data

Setelah model LSTM selesai dilatih, tahap selanjutnya adalah menguji model dengan data uji (Testing Data) untuk mengevaluasi seberapa baik kinerjanya. Data uji adalah bagian dari dataset yang tidak digunakan saat pelatihan, dan dalam penelitian ini, 20% dari total data digunakan sebagai data uji.

2.8 Prediksi

Prediksi merupakan langkah selanjutnya setelah model dilatih, Model akan membuat prediksi berdasarkan data uji, dan hasil prediksi tersebut akan dibandingkan dengan nilai yang sebenarnya. Hasil prediksi sering kali berupa angka yang sudah dinormalisasi, yaitu dalam rentang antara 0 hingga 1, agar hasil prediksi bisa dipahami dengan jelas, Dilakukan denormalisasi, yaitu mengembalikan angka

prediksi ke skala yang asli, Denormalisasi dilakukan dengan menggunakan parameter yang sama seperti yang digunakan saat normalisasi. Dengan cara tersebut, hasil prediksi bisa dibandingkan dengan data yang sebenarnya dan lebih mudah dipahami.

2.9 Evaluasi Model

Evaluasi model bertujuan untuk mengetahui ketepatan dari model yang telah dibuat. Pada penelitian ini model yang telah di latih dievaluasi menggunakan metrik Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), dan R-squared (R^2). Berikut rumus matematis metrik tersebut:

a) *Mean Absolute Error (MAE)*

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

b) *Root Mean Squared Error (RMSE)*

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

c) *Mean Absolute Percentage Error (MAPE)*

$$MAPE = \frac{\sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{y_t}}{n} \times 100\% \quad (9)$$

Tabel. 1 Kriteria Nilai MAPE

Range MAPE	Arti
<10%	Kemampuan model Sangat baik
10-20%	Kemampuan Model Baik
20-50%	Kemampuan Model Sedang
>50%	Kemampuan Model Buruk

d) *R-squared (R^2)*

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

3. HASIL DAN PEMBAHASAN

3.1 Identifikasi Data

Pada pembahasan diatas, dijelaskan bahwa dataset yang digunakan merupakan data historis kunjungan wisatawan mancanegara ke Indonesia berdasarkan pintu masuk kedatangan dan berfokus pada tiga jenis pintu masuk utama, yaitu pintu masuk udara, laut, dan darat Selama periode Januari 2008 hingga Desember 2024, dengan total sebanyak 204 data. Berikut hasil pengambilan data dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pengambilan Dataset

	Tahun	Bulan	Pintu Udara	Pintu Laut	Pintu Darat
1	2008	1	270189	89296	1043
2	2008	2	294147	102762	1613
3	2008	3	312324	108215	1610
4	2008	4	285113	93401	1234
5	2008	5	321657	105042	1606
6	2008	6	327611	115706	1553
.....					
.....					
199	2024	7	994583	212433	103740
200	2024	8	987547	248758	103641
201	2024	9	941903	231748	105607
202	2024	10	859747	218620	115500
203	2024	11	756972	223293	111802
204	2024	12	832865	300766	110740

3.2 Pelatihan Model

3.2.1 Normalisasi Data


Data yang dinormalisasi ini telah melalui tahapan pra-pemrosesan yang meliputi pembersihan data (data cleansing) untuk menghilangkan data yang tidak relevan atau outlier, transformasi data atau pengurutan data berdasarkan rentang waktu agar sesuai dengan format analisis yang diinginkan, serta normalisasi data menggunakan *MinMaxScaler* agar rentang data menjadi [0, 1] sehingga tidak ada perbedaan skala data yang menyebabkan model pembelajaran mesin menjadi tidak akurat. Berikut hasil saat proses normalisasi data, dapat dilihat pada Gambar 2.

3.2.2 Training Model


Dalam proses pelatihan model pada penelitian ini, data terlebih dahulu dibentuk menjadi dataset *time series* dengan menggunakan pendekatan windowing, yaitu 12

bulan sebelumnya (time step) digunakan sebagai input untuk memprediksi bulan berikutnya. Setelah dataset time series terbentuk, data kemudian dibagi menjadi 80% untuk pelatihan (training) dan 20% untuk pengujian (testing), dilakukan secara terpisah untuk setiap kategori pintu masuk. Selanjutnya, model dilatih menggunakan arsitektur *Long Short-Term Memory* (LSTM) untuk memprediksi kunjungan wisatawan mancanegara berdasarkan pola historis tersebut. Setiap pintu masuk menggunakan arsitektur model yang sama, yaitu dua lapisan LSTM dengan masing-masing 64 neuron, disertai dropout sebesar 0,1 pada kedua lapisan tersebut, serta satu lapisan Dense di bagian akhir. Model dikompilasi menggunakan optimizer Adam dengan fungsi loss *Mean Squared Error* (MSE) dan *learning rate* sebesar 0,005.. Model terbaik diperoleh setelah melalui beberapa kali percobaan pelatihan, yaitu dengan menggunakan 20 *epoch* dan *batch size* 16, menghasilkan nilai loss yang cukup baik. Untuk pintu Udara, nilai loss yang diperoleh adalah 0.0094, sementara pintu laut yang menggunakan konfigurasi yang sama (20 *epochs* dan *batch size* 16) menghasilkan nilai loss 0.0103. Terakhir, pintu darat dengan konfigurasi pelatihan serupa menghasilkan nilai loss sebesar 0.0048.


Visualisasi grafik loss dari masing-masing model dapat dilihat pada Gambar 3, 4, dan 5 berikut.



Gambar 4. Loss Pintu Udara



Gambar 5. Loss Pintu laut



Gambar 6. Loss Pintu Darat

3.3 Evaluasi Model

Berdasarkan hasil uji coba model LSTM, dapat disimpulkan bahwa metode deep learning dengan algoritma *Long Short-Term Memory* (LSTM) mampu memberikan performa prediksi yang baik dalam memodelkan jumlah kunjungan wisatawan mancanegara berdasarkan kategori pintu masuk. Hasil evaluasi model terbaik untuk masing-masing kategori ditunjukkan pada Tabel 3.

Tabel 3. Hasil Evaluasi Model

Kategori	RMSE	MAE	MAPE	R2
Pintu Udara	73133.52	57747.22	17.56%	0.9405
Pintu Laut	37267.33	28368.17	15.44%	0.7542
Pintu Darat	13871.17	9511.75	12.51%	0.3728


3.4 Analisis Prediksi

3.4.1 Visualisasi Aktual Vs Prediksi

Visualisasi hasil evaluasi model digunakan untuk menggambarkan kemampuan model LSTM dalam melakukan prediksi berdasarkan data historis jumlah wisatawan mancanegara.

Visualisasi grafik perbandingan antara nilai aktual dan hasil prediksi model LSTM pada


setiap pintu masuk dapat dilihat pada Gambar 6, 7, dan 8 berikut.



Gambar 7. Perbandingan Nilai Aktual Vs Prediksi Pintu Udara


Berdasarkan grafik perbandingan antara nilai aktual dan prediksi jumlah wisatawan mancanegara melalui pintu udara, terlihat bahwa model LSTM berhasil mempelajari pola tren jangka panjang dengan baik. Mulai dari awal 2022 hingga akhir 2024, model mampu mengikuti arah pergerakan data aktual, khususnya pada tren kenaikan yang signifikan sepanjang tahun 2022 dan 2023.

Secara keseluruhan, grafik ini menunjukkan bahwa model LSTM memiliki kinerja yang baik dalam memprediksi jumlah wisatawan melalui pintu udara, dengan akurasi tinggi dan keselarasan tren terhadap data aktual. Kemampuan model dalam memetakan pola deret waktu pada jalur udara menunjukkan bahwa jalur ini memiliki karakteristik data yang lebih stabil dan mudah dipelajari oleh model.



Gambar 8. Perbandingan Nilai Aktual Vs Prediksi Pintu Laut.

Berdasarkan grafik perbandingan antara nilai aktual dan prediksi jumlah wisatawan mancanegara melalui pintu laut, Secara umum, model LSTM mampu menangkap pola tren kenaikan dan penurunan jumlah wisatawan dengan cukup baik.




Gambar 9. Perbandingan Nilai Aktual Vs Prediksi Pintu Darat

Berdasarkan grafik perbandingan antara nilai aktual dan prediksi jumlah wisatawan mancanegara melalui pintu darat, dapat dilihat bahwa model LSTM mampu mengikuti tren umum dari data aktual, terutama pada periode 2023 hingga 2024. Namun, terlihat bahwa pada awal 2022 hingga pertengahan 2023, terdapat beberapa deviasi atau perbedaan yang cukup signifikan antara nilai aktual dan prediksi. Hal ini menunjukkan bahwa model mengalami kesulitan dalam menangkap fluktuasi tajam dan perubahan mendadak yang terjadi pada data kunjungan melalui pintu darat. Meskipun demikian, prediksi model menunjukkan konsistensi dan kestabilan pola, khususnya setelah pertengahan 2023, di mana garis prediksi cenderung mendekati dan bergerak searah dengan data aktual. Ini menunjukkan bahwa model LSTM mampu beradaptasi dengan pola historis setelah periode pembelajaran yang cukup.


3.4.2 Visualisasi Forecasting

Visualisasi forecasting ini bertujuan untuk menggambarkan proyeksi jumlah kunjungan wisatawan mancanegara melalui pintu masuk selama 12 bulan ke depan, berdasarkan pola historis yang telah dipelajari oleh model *Long Short-Term Memory* (LSTM).

Visualisasi grafik hasil prediksi model LSTM selama 12 bulan kedepan untuk masing-masing kategori pintu masuk dapat dilihat pada Gambar 9, 10, 11 berikut:



Gambar 10. Prediksi 12 bulan ke depan Pintu Udara



Gambar 11. Prediksi 12 bulan ke depan Pintu Laut



Gambar 12. Prediksi 12 bulan ke depan Pintu Darat

Berdasarkan hasil prediksi jumlah kunjungan wisatawan mancanegara ke Indonesia selama 12 bulan ke depan menggunakan model LSTM pada data time series, diperoleh bahwa pintu masuk udara menunjukkan performa paling stabil dengan tren kenaikan bertahap, mencerminkan pemulihan positif sektor pariwisata. Pada pintu masuk laut, model mampu menangkap pola musiman dengan prediksi kenaikan perlahan namun stabil. Sementara pada pintu masuk darat, model berhasil merepresentasikan fluktuasi signifikan dengan tren menurun secara moderat. Secara keseluruhan, LSTM terbukti efektif dalam memodelkan tren kunjungan wisatawan berdasarkan ketiga kategori pintu masuk, sehingga dapat menjadi dasar penting bagi

perumusan strategi kebijakan pariwisata Indonesia.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode *Long Short-Term Memory* (LSTM) mampu memberikan performa prediksi yang baik dalam memodelkan kunjungan wisatawan mancanegara berdasarkan pola data deret waktu (time series) dengan *time step* selama 12 bulan. Hasil evaluasi menunjukkan bahwa model memberikan performa yang baik pada kategori pintu masuk udara, dengan nilai RMSE 73.133,52, MAE 57.747,22, MAPE 17,56%, dan R^2 0,9405. Pada pintu laut, model juga menunjukkan hasil yang baik dengan nilai RMSE 37.267,33, MAE 28.368,17, MAPE 15,44%, dan R^2 0,7542. Sementara itu, pintu darat menunjukkan nilai RMSE 13.871,17, MAE 9.511,75, MAPE 12,51%, dan R^2 0,3728. Perbedaan Tingkat akurasi pada masing-masing pintu masuk disebabkan oleh kompleksitas dan variasi pola data yang dimiliki oleh masing-masing kategori.

Meskipun model LSTM menunjukkan performa prediksi yang baik, penelitian ini masih memiliki beberapa keterbatasan, seperti hanya menggunakan satu variabel (univariate), data yang digunakan bersifat bulanan, serta belum dilakukan perbandingan dengan metode lain. Untuk pengembangan selanjutnya, disarankan membandingkan LSTM dengan algoritma lain seperti GRU, Bidirectional LSTM, atau metode deep learning lainnya. Analisis multivariate dengan menambahkan variabel lain dan penggunaan data harian juga perlu dipertimbangkan, karena data per hari dapat menangkap dinamika kunjungan secara lebih detail dan dapat berpotensi meningkatkan akurasi prediksi.

UCAPAN TERIMA KASIH

Penulis sangat mengucapkan terimakasih terhadap semua pihak yang ikut membantu

penulis dalam terselesaikannya tugas akhir ini, kepada kedua orang tua yang telah ikut membantu mendoakan penulis, sehingga penelitian dapat terselesaikan dengan baik, juga kepada Universitas Islam Madura yang telah memberikan fasilitas terhadap kami untuk terus melakukan inovasi dan menyelesaikan pendidikan. Terutama juga kepada dosen pembimbing yang telah membimbing penulis dalam menyelesaikan tugas Akhir ini.

DAFTAR PUSTAKA

- [1] H. Fadilla, "Pengembangan Sektor Pariwisata untuk Meningkatkan Pendapatan Daerah di Indonesia," *Benefit J. Bussiness, Econ. Financ.*, vol. 2, no. 1, pp. 36–43, 2024, doi: 10.37985/benefit.v2i1.375.
- [2] M. H. Aziz, "Model Pariwisata Digital dalam Pengembangan Pariwisata Indonesia," *J. Ilm. Univ. Batanghari Jambi*, vol. 22, no. 3, p. 2279, 2022, doi: 10.33087/jiubj.v22i3.2246.
- [3] N. S. Fakdawer, Y. Boari, S. Y. Manginte, and M. Walilo, "Strategi Pengembangan Objek Wisata Dalam Upaya Peningkatan Kunjungan (Studi pada Objek Wisata Danau Love di Sentani Timur)," *Realis. Law Rev.*, vol. 1, no. 3, pp. 56–78, 2023, [Online]. Available: <https://journal.sabtida.com/index.php/rlr/article/view/24/11>
- [4] H. Mukhtar, R. Muhammad, T. Reny Medikawati, and Yoze Rizki, "Peramalan Kedatangan Wisatawan Mancanegara Ke Indonesia Menurut Kebangsaan Perbulannya Menggunakan Metode Multilayer Perceptron," *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 2, no. 2, pp. 113–119, 2021, doi: 10.37859/coscitech.v2i2.3324.
- [5] A. Meimela, "Prediksi Jumlah Kunjungan Wisatawan Mancanegara ke Indonesia," *Media Wisata*, vol. 19, no. 1, pp. 34–41, 2021, doi: 10.36276/mws.v19i1.64.
- [6] S. Nurman, M. Nusrang, and Sudarmin, "Analysis of Rice Production Forecast in Maros District Using the Box-Jenkins Method with the ARIMA Model," *ARRUS J. Math. Appl. Sci.*, vol. 2, no. 1, pp. 36–48, 2022, doi: 10.35877/mathscience731.
- [7] W. A. P. Wanto Anjar, "Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan MWanto, A. (2019). Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation. Jurnal & Penelitian Teknik Infor," *J. Penelit. Tek. Inform.*, vol. 2, no. 2, pp. 37–44, 2020, [Online]. Available: <https://zenodo.org/record/1009223#.Wd7norlTbhQ>
- [8] S. A. Salimu and Y. Yunus, "Prediksi Tingkat Kedatangan Wisatawan Asing Menggunakan Metode Backpropagation (Studi Kasus: Kepulauan Mentawai)," *J. Inform. Ekon. Bisnis*, vol. 2, pp. 98–103, 2020, doi: 10.37034/infeb.v2i4.50.
- [9] I. O. Arissinta, I. D. Sulistiyawati, D. Kurnianto, and I. Kharisudin, "Pemodelan Time Series untuk Peramalan Web Traffic," *Prism. Pros. Semin. Nas. Mat.*, vol. 5, pp. 693–700, 2022.
- [10] A. Oktaviani and Hustinawati, "Prediksi Rata-Rata Zat Berbahaya Di Dki Jakarta Berdasarkan Indeks Standar Pencemar Udara Menggunakan Metode Long Short-Term Memory," *J. Ilm. Inform. Komput.*, vol. 26, no. 1, pp. 41–55, 2021, doi: 10.35760/ik.2021.v26i1.3702.
- [11] F. Mu'minin, F. Fauziah, and A. Gunaryati, "Prediksi Kunjungan Wisatawan Mancanegara Melalui Pintu Udara Menggunakan ARIMA, Glmnet, dan Prophet," *Techno.Com*, vol. 21, no. 1, pp. 149–157, 2022, doi: 10.33633/tc.v21i1.5695.
- [12] P. A. Nulhakim, C. Chairunisah, and A. Arnita, "Prediksi Jumlah Wisatawan Mancanegara Ke Sumatera Utara Berdasarkan Pintu Masuk Utama Menggunakan Algoritma Backpropagation Neural Network," *J. Ilm. Ilk. - Ilmu Komput. Inform.*, vol. 7, no. 2, pp. 78–89, 2024, doi: 10.47324/ilkominfo.v7i2.264.
- [13] A. Prayuda and I. Pratama, "Prediksi Jumlah Kedatangan Wisatawan Mancanegara Di Indonesia Berdasarkan Pintu Masuk Kedatangan Udara," *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 9, no. 2, pp. 232–241, 2024, doi: 10.36341/rabit.v9i2.4787.