

APLIKASI PREDIKSI KEDATANGAN WISATAWAN MANCANEGERA KE INDONESIA DENGAN ALGORITMA LONG SHORT-TERM MEMORY (LSTM)

Anggun Lisnawati, Syariful Alam, Imay Kurniawan

Teknik Informatika, STT Wastukencana

Jl.Cikopak No.53, Kec Purwakarta, Purwakarta, Jawa Barat, Indonesia-41151

anggunlisnawati19@wastukencana.ac.id


ABSTRAK

Pariwisata memiliki peran penting dalam perekonomian Indonesia, di mana wisatawan mancanegara memberikan kontribusi terhadap PDB dan penciptaan lapangan kerja. Pemerintah Indonesia menargetkan kedatangan wisatawan asing antara 14,6 hingga 16 juta pada tahun 2025. Namun, untuk merumuskan kebijakan dan strategi pengembangan pariwisata yang efektif, prediksi kedatangan wisatawan asing yang akurat sangat diperlukan. Penelitian ini bertujuan untuk memprediksi jumlah wisatawan mancanegara yang akan datang ke Indonesia menggunakan algoritma Long Short-Term Memory (LSTM), yang dikenal efektif dalam menangani data deret waktu. Metodologi penelitian ini mengikuti kerangka kerja CRISP-DM (Cross Industry Standard for Data Mining), yang terdiri dari enam tahap: Pemahaman Bisnis, Pemahaman Data, Persiapan Data, Pemodelan, Evaluasi, dan Penerapan. Dataset yang digunakan adalah catatan kedatangan wisatawan mancanegara dari tahun 2017 hingga 2024, yang diproses dan dinormalisasi menggunakan MinMaxScaler untuk meningkatkan kestabilan. Model LSTM diterapkan dengan tiga lapisan (64, 32, dan 1 neuron), dan Adam optimizer digunakan untuk optimasi. Hasil evaluasi menunjukkan akurasi yang sangat baik dengan Mean Absolute Percentage Error (MAPE) sebesar 7,73% dan Mean Absolute Error (MAE) sebesar 84.737. Prediksi untuk tahun 2025 menunjukkan tren yang stabil, dengan kedatangan wisatawan bulanan berkisar antara 1,09 juta hingga 1,19 juta. Model ini kemudian dideploy menggunakan Streamlit

Kata kunci : *Prediksi Wisatawan, LSTM, Time Series, CRISP-DM, MAPE, Pariwisata Indonesia*

1. PENDAHULUAN

Indonesia negara dengan keanekaragaman dan kekayaan alam yang besar Pasal 1 Ayat 1 Undang-Undang Nomor 10 Tahun 2009 tentang Kepariwisataan, pariwisata adalah berbagai jenis wisata yang didukung oleh sarana dan prasarana yang disediakan oleh masyarakat, pengusaha, pemerintah, dan Pemerintah Daerah, Menurut Haryo Limanseto, Kementerian Pariwisata dan Ekonomi Kreatif (Kemenparekraf) berharap lebih banyak wisatawan asing datang ke Indonesia karena mereka berkontribusi besar terhadap Produk Domestik Bruto (PDB) dan penciptaan lapangan kerja [1]. Pemerintah Indonesia menargetkan jumlah wisatawan asing mencapai 14,6 juta hingga 16 juta pada tahun 2025, menurut Kementerian Pariwisata dan Ekonomi Kreatif (Kemenparekraf) [2].



Gambar 1. Total Kunjungan Wisman

Jumlah wisatawan asing yang datang ke Indonesia pada tahun 2017 hingga tahun 2024 menurut Badan Pusat Statistik. Jumlah wisatawan yang datang pada tahun 2020 turun drastis, menjadi hanya 1.555.730 orang. Ini mungkin karena dampak pandemi COVID-19 terhadap perjalanan internasional. Jumlah pengunjung meningkat dari 2021 hingga 2024. Data ini menunjukkan banyak perubahan, dengan penurunan tajam pada tahun 2020 dan pemulihan yang lebih baik di tahun-tahun berikutnya, yang menunjukkan tren kedatangan wisatawan mancanegara selama masa itu [3].

Namun kedatangan jumlah pengunjung perlu diprediksi untuk mengantisipasi fluktuasi, supaya negara dapat menetapkan kebijakan terkait perubahan jumlah Wisatawan Mancanegara di masa depan. Misalnya untuk menjaga keseimbangan keuangan negara agar tidak mengalami penurunan apabila jumlah pengunjung menurun [4]. *Long Short-Term Memory* (LSTM) adalah pengembangan dari algoritma *Recurrent Neural Network* (RNN). LSTM dianggap lebih baik daripada algoritma lain dalam hal pengelolaan data *Time Series* [5].

Penerapan algoritma *Long Short-Term Memory* (LSTM) pada penelitian ini sangat relevan dan dapat implementasikan untuk memprediksi jumlah kedatangan wisatawan mancanegara yang diharapkan akan berkunjung ke Indonesia, dengan mengintegrasikan data historis dan tren yang muncul, algoritma ini dapat menghasilkan prediksi yang lebih akurat untuk merumuskan kebijakan yang lebih efektif dalam menarik wisatawan internasional.

2. TINJAUAN PUSTAKA

Penelitian terdahulu oleh [6] dengan judul *Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short Term Memory (LSTM)* dipenelitian ini dapat menghasilkan performa yang lebih baik, dengan hasil eksperimen penelitian menghasilkan pemodelan LSTM dengan performa *Mean Everage Presentage Error (MAPE)* sebesar 0.4214 dan *Mean Average Error (MAE)* sebesar 0.3292.

2.1. Aplikasi

Perangkat lunak teknologi informasi yang dapat dilihat tetapi tidak dapat disentuh disebut aplikasi [7] Secara umum, aplikasi terbagi menjadi tiga platform yaitu *mobile*, *desktop*, dan *web*[8].

2.2. Prediksi

Prediksi atau *forecasting* merupakan suatu teknik untuk meramalkan kejadian di masa mendatang berdasarkan kondisi dan situasi saat ini maupun masa mendatang. Terdapat berbagai perspektif berbeda mengenai metode peramalan dari masing-masing kelompok metode ilmiah yang digunakan untuk mengevaluasi keputusan. Metode Peramalan akan memberikan estimasi yang baik mengenai cakrawala waktu dan panduan untuk peramalan dan Keputusan [9].

2.3. Long Short-Term Memory

Pada tahun 1997, Hochreiter dan Schmidhuber memperkenalkan LSTM, jenis RNN yang secara khusus dirancang untuk mengatasi masalah jangka panjang ketergantungan. Karena struktur jaringan berulangnya yang unik, *Long Short-Term Memory* dapat dengan mudah mengingat informasi untuk jangka waktu yang lama [10]. yang dirancang untuk mengatasi masalah pada RNN, khususnya gradien menghilang (*vanishing gradient*) dan gradien meledak (*ledakan gradient*) selama pembelajaran data yang disimpan dalam memori panjang. Hasilnya, LSTM cocok digunakan untuk kasus prediksi dan klasifikasi yang memiliki hubungan dengan waktu [11].

2.4. Badan Pusat Statistik

Badan Pusat Statistik (BPS) merupakan lembaga swadaya masyarakat yang memberikan nasihat langsung kepada presiden. Berdasarkan UU No. 6 Tahun 1960 tentang Sensus dan UU No. 7 Tahun 1960 tentang Statistik, BPS sebelumnya merupakan Biro Pusat Statistik. Berdasarkan kedua UU tersebut di atas, maka dibentuklah UU No. 16 Tahun 1997 tentang Statistik [12].


2.5. Streamlit

Streamlit adalah *framework* open-source berbasis *Python* yang dirancang untuk memfasilitasi pengembangan aplikasi *web* interaktif di bidang ilmu data dan pembelajaran mesin. Satu hal yang menonjol dari *framework* ini adalah tidak perlu banyak memahami tentang teknologi pengembangan *web*.

Kita tidak perlu membahas cara menggunakan CSS, HTML, atau *Javascript* untuk memodifikasi situs *web*. *Python* adalah modal dasar untuk membuat *Streamlit*, [13].

3. METODE PENELITIAN

Metode penelitian yang diterapkan dalam studi ini berlandaskan pada metode CRISP-DM. CRISP-DM (*Cross Industry Standard for Data Mining*) merupakan metodologi yang banyak digunakan oleh para ahli yang menggunakan proses pemodelan data. Tujuan dari metode CRISP-DM adalah untuk mengidentifikasi pola-pola yang menarik dan bermakna dalam data yang digunakan. CRISP-DM memiliki kerangka kerja dan tahapan yang terstruktur, sehingga memungkinkan pengguna metodologi ini untuk lebih terarah dan menyadari langkah-langkah yang diperlukan untuk dilakukan dalam aktivitas ini. CRISP-DM terdiri dari 6 tahapan diantaranya *Bussiness Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment* [14].



Gambar 2. Kerangka Penelitian

a. Bussines Understanding

Tahap untuk menentukan tujuan bisnis untuk memahami situasi dan kondisi pada saat penelitian.

b. Data Understanding

Tahap untuk memahami dataset yang akan digunakan dan melakukan identifikasi kualitas

dataset, pada tahap ini dataset ditampilkan agar mengetahui data yang akan di proses pada tahap selanjutnya

c. **Data Preparation**

Tahap untuk memproses data setelah data di identifikasi, selanjutnya data biasanya dilakukan data cleaning, melakukan pemilihan data, dan Transformasi data

d. **Modeling**

Tahap proses implementasi Algoritma LSTM

e. **Evaluation**

Tahap melakukan pengukuran hasil dari model yang sudah diimplementasikan. Hasil dari evaluasi ini menggambarkan visualisasi proses dari data mining yang telah dilakukan dan mengukur seberapa baik model digunakan

f. **Deployment**

Tahap melakukan laporan atau penyebaran presentasi hasil dari data mining.

4. HASIL DAN PEMBAHASAN

4.1. Business Understanding

Metode *Long Short-Term Memory* (LSTM) digunakan dalam penelitian adalah ini untuk menghasilkan hasil prediksi pola tren jumlah wisman yang datang ke Indonesia. Hal ini bertujuan untuk mengantisipasi fluktuasi jumlah wisatawan, sehingga negara dapat merumuskan kebijakan yang sesuai terhadap perubahan jumlah pengunjung di masa depan.

4.2. Data Understanding

Data yang didapatkan berasal dari Badan Pusat Statistik,

The screenshot shows the BPS website interface. The main content area displays a table titled 'Jumlah Kunjungan Wisatawan Mancanegara per bulan ke Indonesia Menurut PINTU MASUK, 2008 - sekarang (Kunjungan), 2017'. The table has columns for 'Pintu Masuk' (A, B, C, D, E, F, G, H, I, J, K, L, M, N, O, P, Q, R, S, T, U, V, W, X, Y, Z) and 'Jumlah Kunjungan' (Januari, Februari, Maret, April, Mei, Juni, Juli, Agustus, September, Oktober, November, Desember). The data is presented in a grid format with alternating light and dark rows.

Gambar 3. Dataset BPS

Data ini memiliki 36 Baris dan 15 kolom per tahun dan bila ditotalkan dengan `pd.concat()` data ini memiliki 15 kolom dengan 280 baris, didalam dataset ini berisikan jumlah wisman yang mengunjungi Indonesia, dataset yang didapat terdiri dari :

Tabel 1. Dataset

Data	Keterangan
Piintu Masuk	Tempat akses masuk
Januari - Desember	Data Kunjungan Bulanan
Tahunan	Total Data bulanan
Tahun	Tahun data 2017 - 2024

Berikut adalah data mentah kunjungan wisatawan 2017 – 2024

Pintu Masuk	Januari	Februari	Maret	April	Mei	Juni	Juli	Agustus	September	Oktober	November	Desember	Tahunan	Tahun
0 A. Pintu Udara	746666	720428	749150	812927	809841	783470	1002611	1014475	883842	802479	701307	663359	9670055	2017
1 Ngurah Rai	455930	448157	424134	477408	488698	505976	584238	601553	551968	484703	360043	308440	5882248	2017
2 Soekarno-Hatta	203067	191933	222497	228811	220817	174669	297360	289000	227687	232014	231183	230483	2749321	2017
3 Juanda	17279	11998	15844	21461	20447	19658	25252	25330	21690	20439	24360	23208	247186	2017
4 Kualanamu	18457	15880	20767	18273	18013	18484	20437	25201	19150	20738	23308	26015	246551	2017

Gambar 4. Data Mentah

4.3. Data Preparation

Pada tahap ini berfungsi untuk memproses data, menyusun data agar terstruktur dan menghilangkan anomali yang akan digunakan dalam pemodelan. Berikut adalah langkah yang harus diambil

4.4. Pembersihan data

Melakukan pembersihan dataset yaitu dengan mengisi data kosong dengan `df.fillna(0)`, mengganti data “-” dengan 0 agar dapat dihitung, dan menghapus tanda “,” koma didalam dataframe. Data yang telah di ubah dari bentuk lebar ke dalam panjang dengan hasil adalah sebagai berikut.

	Pintu Masuk	Tahun	Bulan	Jumlah_Wisatawan
0	a. pintu udara	2017	1	746666
1	ngurah rai	2017	1	455930
2	soekarno-hatta	2017	1	203067
3	juanda	2017	1	17279
4	kualanamu	2017	1	18457

Gambar 5. Hasil Data Cleaning

4.5. Pemilihan Data

Untuk proses pemilihan data melakukan penggabungan kolom Tahun dan Bulan agar data menjadi data *Time Series* dengan `dtype "datetime"` hasil penggabungan ditambahkan kedalam kolom “Tahun – Bulan”. Selanjutnya melakukan pemilihan data, data yang akan di proses adalah data dari kolom Pintu Masuk berisikan “total”, kolom “Jumlah_Wisatawan” serta kolom “Tahun-Bulan” sebagai visualisasi kedatangan berdasarkab Tahun dan bulan data yang akan di uji.

Unnamed: 0	Pintu Masuk	Tahun	Bulan	Jumlah_Wisatawan	Tahun-Bulan
0	34	total	2017	1	1107968 2017-01-01
1	69	total	2018	1	1097839 2018-01-01
2	104	total	2019	1	1201735 2019-01-01
3	139	total	2020	1	1290411 2020-01-01
4	174	total	2021	1	126515 2021-01-01

Gambar 6. Pemilihan Data

4.6. Transformasi Data

Melakukan normalisasi data yaitu “Jumlah_Wisatawan” yang mengalami transformasi melalui normalisasi menggunakan `MinMaxScaler()`. Pada tahap ini, normalisasi data dilakukan untuk

mengurangi kesalahan saat pengujian model prediksi sehingga perhitungan menjadi lebih stabil [15]

Tabel 2. Hasil Normalisasi Data

Data asli (Belum dinormalisasi)	Data Ternormalisasi
[1107968]	[0.69526162]
[1023388]	[0.63658431]
[1059777]	[0.66182915]
[1171386]	[0.73925781]
[1148588]	[0.72344172]
[1144001]	[0.72025949]

```
# 3. Membuat Dataset
def create_dataset(data, time_steps=12):
    X, y = [], []
    for i in range(len(data)-time_steps):
        X.append(data[i:(i+time_steps), 0])
        y.append(data[i+time_steps, 0])
    return np.array(X), np.array(y)

X, y = create_dataset(data_scaled, time_steps=12)
X = X.reshape(X.shape[0], X.shape[1], 1)
```

Gambar 7. Penyesuaian Dataset

Data set yang dimiliki saat ini adalah data set 2D yaitu (jumlah sampel, jumlah *time steps*) dengan *time_steps*=12 yang berarti data yang akan di ambil sebanyak 12 bulan agar mengetahui pola data selama 1 tahun. Data tersebut di reshape menjadi 3D yaitu (jumlah sampel, jumlah time steps, jumlah fitur) agar sesuai dengan kebutuhan LSTM.

4.7. Modeling

Melakukan pemodelan menggunakan model LSTM, yang sesuai untuk kasus prediksi dan klasifikasi yang berkaitan dengan waktu (*Time Series*) [11]. Memanfaatkan *sequential()* pada Keras untuk mengatur lapisan secara berurutan, menggunakan aktivasi ReLU, menggabungkan tiga lapisan dengan 64 *neuron* di lapisan pertama, 32 *neuron* di lapisan kedua, dan lapisan padat dengan 1 *neuron*, dioptimalkan menggunakan kompilasi model "adam".

```
# 5. Bangun Model
model = Sequential([
    LSTM(64, activation='relu', input_shape=(12, 1), return_sequences=True),
    LSTM(32, activation='relu'),
    Dense(1)
])
model.compile(optimizer='adam', loss='mse')
```

Gambar 8. Model LSTM

Selanjutnya, dilakukan perbandingan dengan melatih data sebanyak 50, 100, dan 150 *epoch* menggunakan batch size 32 untuk menentukan hasilnya. *Output* dari proses pelatihan ini disimpan, mencakup informasi seperti nilai akurasi dan kerugian selama pelatihan dan validasi pada setiap *epoch*.

4.8. Evaluation

Hasil data pemodelan dievaluasi menggunakan dua metrik: MAPE dan MAE. *Mean Absolute Percentage Error* (MAPE) ialah metrik Evaluasi

untuk peramalan yang menghitung persentase rata-rata kesalahan absolut antara nilai peramalan dan permintaan aktual. Nilai MAPE dianggap baik jika hasilnya kurang dari 10%, dengan menggunakan persamaan sebagai berikut [16]

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (1)$$

dengan y_i merupakan nilai aktual data, $\hat{y}_i$ merupakan nilai hasil prediksi, dan n merupakan banyaknya data. Skala untuk menilai akurasi prediksi berdasarkan nilai MAPE dikembangkan oleh Lewis dalam seperti pada Tabel

Tabel 3. Kriteria Nilai MAPE

Interpretasi	Skala MAPE
Sangat Akurat	<10%
Akurat	10 – 20%
Cukup	20 – 50%
Tidak Akurat	>50%

Selanjutnya adalah metode untuk mengevaluasi akurasi model peramalan adalah *Mean Absolute Error* (MAE). Hasil kesalahan absolut rata-rata menunjukkan besarnya kesalahan absolut rata-rata antara nilai aktual dan nilai perkiraan. Untuk menentukan seberapa presisi model peramalan, metode *Mean Absolute Error* (MAE) digunakan untuk mengukur hasil perhitungan prediksi [17].


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

dengan y_i merupakan nilai aktual data, $\hat{y}_i$ merupakan nilai hasil prediksi, $\sum_{i=1}^n$ untuk menjumlahkan banyaknya data $i=1$ hingga n , dan n adalah banyaknya data [18] Hasil *Evaluasi* 2 metrik MAPE dan MAE sebagai berikut.


Tabel 4. Hasil Evaluasi Hasil Metriks

EPOCH	MAPE	MAE
50	9.82%	105346
100	8.12%	91243
150	7.73%	84737


Berikut adalah visualisasi *Validation Loss* per *epoch*nya:



Gambar 9. Validation Loss 50 Epoch



Gambar 10. Validation Loss 100 Epoch



Gambar 11. Validation Loss 150 Epoch

Grafik yang ditampilkan menunjukkan evolusi nilai training Loss dan Validation Loss seiring dengan jumlah epoch (iterasi pelatihan) untuk setiap skenario: 50 epoch, 100 epoch, dan 150 epoch. Pada epoch ke-50, model masih dalam proses pembelajaran dan belum mencapai kinerja optimal. Loss pelatihan menurun, namun Loss validasi mungkin masih berfluktuasi, menunjukkan bahwa model belum sepenuhnya mampu melakukan generalisasi dengan baik. Epoch ke-100 menunjukkan bahwa kehilangan pelatihan terus menurun, sementara kehilangan validasi mulai stabil. Hal ini menunjukkan bahwa model mulai mengidentifikasi pola yang menguntungkan dalam data, dan performa validasinya meningkat. Namun, jika Validation Loss mulai stagnan atau meningkat sementara training Loss terus menurun, ini dapat menjadi indikasi awal *overfitting*. Pada epoch ke-150, kehilangan pelatihan semakin menurun, menunjukkan bahwa model sangat efektif dalam mempelajari data pelatihan. Namun, jika kehilangan validasi mulai meningkat, ini merupakan indikasi *overfitting*, di mana model terlalu beradaptasi dengan data pelatihan dan kinerjanya pada data baru menurun. Performa model menunjukkan optimal pada 100 epoch, terdapat keseimbangan antara akurasi pelatihan dan validasi, serta belum menunjukkan indikasi *overfitting*. Ini adalah hasil prediksi untuk Januari hingga Desember 2024 dengan epoch 100.


Tabel 5. Hasil Aktual dan Prediksi

Bulan	Aktual	Prediksi
Jan-2024	927746	1086803
Feb-2024	1062149	1099129
Mar-2024	1041861	1113967
Apr-2024	1066958	1126101
May-2024	1145499	1138892

Bulan	Aktual	Prediksi
Jun-2024	1197941	1149442
Jul-2024	1310756	1156430
Aug-2024	1339946	1160175
Sep-2024	1279258	1162784
Oct-2024	1193867	1166290
Nov-2024	1092067	1172092
Dec-2024	1244372	1179998

Tabel 6. Hasil prediksi untuk bulan Januari 2025 – Desember 2025

Bulan	Jumlah Wisatawan
Jan-2025	1,192,396
Feb-2025	1,175,813
Mar-2025	1,161,190
Apr-2025	1,147,285
May-2025	1,135,036
Jun-2025	1,126,230
Jul-2025	1,117,211
Aug-2025	1,112,502
Sep-2025	1,108,952
Oct-2025	1,105,712
Nov-2025	1,102,047
Dec-2025	1,097,787



Gambar 12. Visualisasi Hasil prediksi untuk bulan Januari 2025 – Desember 2025

4.9. Deployment

Melakukan *Deployment* model yang telah dibangun kedalam web *Streamlit*. Sehingga dapat digunakan oleh siapapun yang membutuhkan untuk memprediksi data Wisatawan Mancanegara di Indonesia. Berikut adalah beberapa fitur pada aplikasi ini:

4.10. Fitur Panduan Penggunaan


Terdapat penjelasan mengenai aplikasi Prediksi Wisata Mancanegara ke Indonesia, diantaranya panduan dalam mengatur parameter dan panduan cara penggunaan aplikasi.



Gambar 13. Fitur Panduan Penggunaan

4.11. Fitur Memilih Data

Fitur untuk pengguna memilih data yang akan di prediksi selanjutnya data yang dipilih dapat ditampilkan datanya.



Gambar 14. Fitur Memilih Data

4.12. Fitur Parameter Model

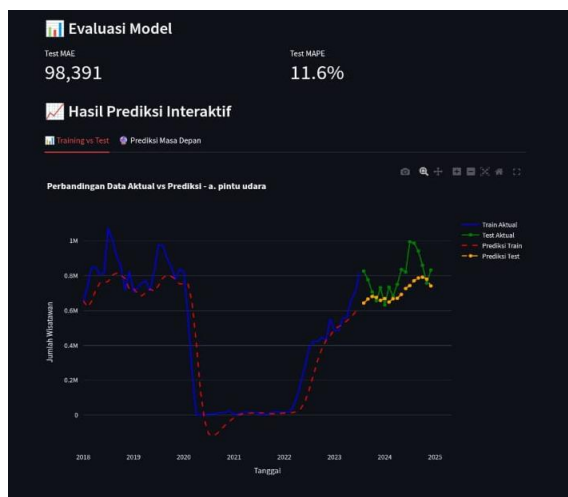
Pada fitur ini pengguna dapat menyesuaikan *Lookback*, *epoch*, dan Prediksi untuk bulan kedepannya, setelahnya model dapat dijalankan.



Gambar 15. Fitur Parameter Model

4.13. Visualisasi Hasil Evaluasi Model

Terdapat hasil Evaluasi model, visualisasi train dan test dan visualisasi prediksi masa depan. Tampilan ini adalah tampilan hasil prediksi dari data pengguna yang dipilih, hasil prediksi dapat di unduh melalui tombol “Download Hasil Prediksi”.



Gambar 16. Visualisasi Hasil Train dan Test



Gambar 17. Visualisasi Hasil Prediksi dan Fitur Download

Berikut adalah tampilan penuh Aplikasi Prediksi Jumlah Wisatawan pada *Streamlit*



Gambar 18. Halaman Penuh

4.14. Tautan Aplikasi

Aplikasi dapat di akses di web *Streamlit* <https://aplikasi-prediksi-wisata-mancanegara-lstm.streamlit.app/>

5. KESIMPULAN DAN SARAN

Penelitian menunjukkan bahwa algoritma LSTM efektif dalam memprediksi jumlah kedatangan wisatawan mancanegara ke Indonesia. Model yang dikembangkan mencapai akurasi tinggi dengan nilai MAPE di bawah 10%, yang menunjukkan keandalan dalam memproyeksikan tren masa depan. Model mencapai kinerja optimal pada 100 *epoch* pelatihan, dengan hasil prediksi yang konsisten untuk tahun 2025. Rekomendasi untuk penelitian lebih lanjut meliputi menambahkan variabel eksternal seperti faktor ekonomi atau kebijakan pariwisata untuk meningkatkan akurasi prediksi, mengeksplorasi algoritma alternatif seperti GRU atau Transformer untuk perbandingan kinerja, dan memperluas cakupan data untuk mencakup lebih banyak tahun guna memperkuat generalisasi model. Bagi para pembuat kebijakan, temuan penelitian ini dapat digunakan untuk merancang strategi pemasaran pariwisata dan alokasi sumber daya yang lebih efisien, terutama dalam menghadapi fluktuasi jumlah wisatawan di masa mendatang.

DAFTAR PUSTAKA

- [1] Haryo Limanseto, “Menjadi Salah Satu Sektor Strategis Dorong Pertumbuhan Ekonomi, Pariwisata Gencar Dikembangkan Pemerintah,” *www.ekon.go.id*. Accessed: Apr. 16, 2025. [Online]. Available: <https://www.ekon.go.id/publikasi/detail/6164/menjadi-salah-satu-sektor-strategis-dorong-pertumbuhan-ekonomi-pariwisata-gencar-dikembangkan-pemerintah#:~:text=Sektor%20pariwisata%20di%20harapkan%20dapat%20menjadi,sejumlah%20destinasi%20wisata%20yang%20menarik.>

- [2] Muhamad Ibrahim, "Kemenpar Bidik Kunjungan 16 Juta Wisman di 2025, Begini Strateginya," Infobanknews.com. Accessed: Apr. 16, 2025. [Online]. Available: <https://infobanknews.com/kemenpar-bidik-kunjungan-16-juta-wisman-di-2025-begini-strateginya/>
- [3] S. Andaryadi, "Jumlah Kunjungan Wisatawan Mancanegara per bulan Menurut Kebangsaan (Kunjungan), 2024," www.bps.go.id. Accessed: Apr. 16, 2025. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/MTQ3MCMY/jumlah-kunjungan-wisatawan-mancanegara-per-bulan-menurut-kebangsaan.html>
- [4] W. Wiratama, L. Aulia Alifah, A. Gurusinga, E. Indra, J. Sistem Informasi, and F. Sains Dan Teknologi, "Prediksi Turis Mancanegara ke Indonesia Menggunakan Metode EDA Time Series dan LSTM," *Jurnal Riset Sistem Informasi Dan Teknik Informatika (JURASIK)*, vol. 8, no. 2, pp. 524–537, 2023, [Online]. Available: <https://tunasbangsa.ac.id/ejurnal/index.php/jurasik>
- [5] Moch Farryz Rizkilloh and Sri Widiyanesti, "Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 25–31, Feb. 2022, doi: 10.29207/resti.v6i1.3630.
- [6] Sabar Sautomo and Hilman Ferdinandus Pardede, "Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 99–106, Feb. 2021, doi: 10.29207/resti.v5i1.2815.
- [7] N. K. Dewi, B. Harira Irawan, E. Fitry, A. S. Putra, and S. M. Jakarta, "Konsep Aplikasi E-Dakwah Untuk Generasi Milenial Jakarta," *IKRA-ITH INFORMATIKA JURNAL KOMPUTER INFORMATIKA*, vol. 5, no. 2, pp. 26–3, Nov. 2020.
- [8] A. N. Yusril, I. Larasati, and P. Al Zukri, "Informasi Systematic Literature Review Analisis Metode Agile dalam Pengembangan Aplikasi Mobile," *SISTEMASI: Jurnal Sistem*, no. 2, p. 369, May 2021, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [9] V. Puspaning Ramadhan, F. Yulian Pamuji, and A. History, "Jurnal Teknologi dan Manajemen Informatika Analisis Perbandingan Algoritma Forecasting dalam Prediksi Harga Saham LQ45 PT Bank Mandiri Sekuritas (BMRI) Article Info ABSTRACT," vol. 8, pp. 39–45, 2022, [Online]. Available: <http://http://jurnal.unmer.ac.id/index.php/jtmi>
- [10] R. Akbar, R. Santoso, and B. Warsito, "PREDIKSI TINGKAT TEMPERATUR KOTA SEMARANG MENGGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM)," *Jurnal Gaussian*, vol. 11, no. 4, pp. 572–579, Feb. 2023, doi: 10.14710/j.gauss.11.4.572-579.
- [11] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, Aug. 2023, doi: 10.23960/jitet.v11i3.3250.
- [12] Adam, "MENGENAL BADAN PUSAT STATISTIK." Accessed: Mar. 14, 2025. [Online]. Available: <https://www.bps.go.id/id>
- [13] Yulianto Muhammad Ichlasul Amal, "Membuat Aplikasi Web Sains Data dengan Mudah Menggunakan Streamlit," <https://informatics.uui.ac.id/2021/03/15/Streamlit-Membuat-Aplikasi-Web-Sains-Data/>.
- [14] F. N. Dhewayani *et al.*, "Implementasi K-Means Clustering untuk Pengelompokkan Daerah Rawan Bencana Kebakaran Menggunakan Model CRISP-DM," *Jurnal Teknologi dan Informasi*, vol. 12 No ` , pp. 64–77, Mar. 2022, doi: 10.34010/jati.v12i1.
- [15] A. Sujjada and F. Sembiring, "Prediksi Harga Bitcoin Menggunakan Algoritma Long ShortTerm Memory," *JURNAL INOVTEK Polbeng*, vol. 9, no. 1, pp. 450–459, 2024.
- [16] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah," *Euler: Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, May 2023, doi: 10.34312/euler.v11i1.19791.
- [17] N. Ichsan, H. Fatah, T. Wahyuni, and E. Ermawati, "IMPLEMENTASI ORANGE DATA MINING UNTUK PREDIKSI HARGA BITCOIN," *JURNAL RESPONSIF*, vol. 4, no. 2, pp. 118–125, 2022, [Online]. Available: <https://investing.com/crypto/bitcoin/historical->
- [18] K. Fatonah, "Prediksi Kasus Tingkat Depresi Mahasiswa Semester Akhir Menggunakan Regresi Linear Sederhana," vol. 7, 2024