



Universitas Nusantara PGRI Kediri

UPT. PERPUSTAKAAN, PUBLIKASI DAN INOVASI

Alamat: Kampus 1, Jl. KH. Ahmad Dahlan No.76 Kota Kediri 64112
Telp. (0354) 771576, (0354) 771503, (0354) 771495, Fax. (0354) 771576
Website: <http://ppi.unpkediri.ac.id/> Email: perpustakaan@unpkediri.ac.id

SURAT KETERANGAN BEBAS SIMILARITY

Ketua UPT Perpustakaan, Publikasi dan Inovasi Universitas Nusantara PGRI Kediri menerangkan bahwa mahasiswa dengan identitas berikut:

Nama Mahasiswa : Firnanda Putra Agustinus
NPM : 2213020150
Program Studi : S1-Teknik Informatika

Judul Karya Ilmiah:

"PERANCANGAN SISTEM PREDIKSI JUMLAH PENGUNJUNG MUSEUM AIRLANGGA KOTA KEDIRI
MENGUNAKAN ALGORITMA LONG SHORT-TERM MEMORY (LSTM)"

Dinyatakan sudah memenuhi syarat batas maksimal 30% *similarity* sesuai dengan ketentuan yang berlaku pada setiap subbab naskah Laporan **Tugas Akhir/Skripsi/Tesis** yang disusun.
Demikian Surat Keterangan ini kami berikan untuk dapat dipergunakan seperlunya.

Kediri, 02 Juli 2026
Ka UPT PPI,



Dr. Abdul Aziz Hunaifi, M.A



2213020150_Firnanda Putra Agustinus (1).pdf

by Turnitin Arise

Submission date: 01-Jul-2026 09:55PM (UTC-0700)

Submission ID: 2992454861

File name: 2213020150_Firnanda_Putra_Agustinus_1_.pdf (1.33M)

Word count: 12133

Character count: 78593

PENDAHULUAN

A. Latar Belakang

Kemajuan teknologi informasi mendorong penerapan digitalisasi pada berbagai bidang, termasuk sektor pariwisata dan pengelolaan museum. Kini tidak lagi hanya berperan sebagai tempat penyimpanan koleksi bersejarah, melainkan juga menjadi pusat informasi dan ruang interaktif yang mendukung peningkatan efisiensi pengelolaan serta kualitas pengalaman pengunjung (Nikolaou, 2024). Pemanfaatan teknologi, terutama analisis data, menjadi faktor penting bagi museum untuk menjaga relevansi dan keberlanjutan di tengah persaingan destinasi wisata (Yap et al., 2024). Di Indonesia, pariwisata dan budaya berkontribusi sebagai salah satu penyumbang penting Pendapatan Asli Daerah (PAD). Sehingga museum perlu beralih dari cara tradisional menuju pendekatan berbasis data agar museum tetap relevan.

Pendekatan berbasis data ini masih belum sepenuhnya dimanfaatkan oleh kebanyakan museum lokal. Seperti Museum Airlangga di Kota Kediri yang masih mengandalkan pencatatan manual (buku tamu) untuk mendata pengunjung. Sistem manual ini rentan terhadap kesalahan *input*, sulit untuk dianalisis secara mendalam, dan tidak mampu memberikan wawasan prediktif yang diperlukan untuk perencanaan operasional. Akibatnya, pengelola museum seringkali harus menentukan jadwal staf, alokasi anggaran promosi, atau penyediaan fasilitas hanya berdasarkan perkiraan dan intuisi, tanpa panduan data yang akurat. Ketidakmampuan ini membuat museum kesulitan dalam menghadapi lonjakan pengunjung, sehingga layanan bisa menurun saat ramai, sekaligus menyebabkan pemborosan sumber daya saat kunjungan rendah (Puspasari et al., 2023)

Untuk mengatasi inefisiensi yang disebabkan oleh pencatatan manual dan ketidakmampuan sistem saat ini dalam memprediksi jumlah pengunjung, muncul kebutuhan mendesak akan sistem yang mampu memberikan prediksi yang akurat. Prediksi ini sangat penting karena jumlah pengunjung museum dipengaruhi oleh berbagai faktor *time series* yang kompleks, seperti hari libur

nasional, libur sekolah, cuaca, dan *event* lokal (Xu et al., 2024). Untuk mengatasinya, *Machine Learning* (ML) hadir sebagai solusi yang efektif. Di antara berbagai metode *Machine Learning*, arsitektur *Deep Learning Long Short-Term Memory (LSTM)* memiliki kemampuan untuk mempelajari pola data deret waktu yang bersifat dinamis dan tidak linear. Karakteristik tersebut menjadikan LSTM sesuai untuk digunakan dalam memperkirakan jumlah kunjungan museum sehingga dapat mendukung proses perencanaan operasional secara lebih efektif. Dengan penerapan ML memungkinkan museum untuk beralih dari manajemen reaktif menjadi manajemen proaktif.

Meskipun ML telah terbukti efektif dalam memprediksi tren pariwisata (Núñez et al., 2024), masih terdapat *research gap*. Sebagian besar penelitian berfokus pada skala makro, seperti prediksi kedatangan turis nasional atau provinsi, dengan data daring yang melimpah. Penelitian spesifik pada prediksi jumlah pengunjung museum tunggal di tingkat kota, seperti Museum Airlangga, masih sangat terbatas. Selain itu, banyak studi masih menggunakan model regresi sederhana yang kurang mampu menangani data multivariat seperti cuaca, kalender, dan faktor lokal. Oleh sebab itu, penelitian ini bertujuan merancang sebuah model prediksi berbasis *Machine Learning* yang mampu memanfaatkan data historis museum sehingga menghasilkan prediksi yang lebih optimal dan dapat diterapkan dalam proses pengelolaan museum.

Sehingga penelitian ini memiliki nilai ilmiah maupun praktis. Dari sisi ilmiah, penelitian ini menunjukkan bagaimana algoritma ML, seperti LSTM dapat digunakan untuk memprediksi kunjungan museum dengan mempertimbangkan faktor eksternal. Dari sisi praktis, penelitian ini menghadirkan prototipe sistem yang membantu Museum Airlangga mengelola sumber daya dan strategi promosi secara efektif. Dengan demikian, studi ini tidak hanya mengisi kekosongan literatur tentang penerapan *Artificial Intelligence* (AI) pada warisan budaya lokal, tetapi juga memberikan solusi nyata bagi peningkatan layanan publik.

B. Identifikasi Masalah

Berdasarkan hasil analisis pada bagian latar belakang, beberapa permasalahan yang terjadi di Museum Airlangga dapat dirumuskan sebagai berikut. Museum Airlangga belum memiliki sistem digital untuk mencatat pengunjung, sehingga semua data masih ditulis manual di buku tamu dan sulit dikelola dengan baik.

C. Rumusan Masalah

Berdasarkan permasalahan mengenai pengelolaan data kunjungan yang belum berjalan secara optimal serta belum tersedianya sistem prediksi di Museum Airlangga, maka rumusan masalah dalam penelitian ini adalah bagaimana merancang sebuah model untuk memperkirakan jumlah kunjungan Museum Airlangga dengan memanfaatkan algoritma *Long Short-Term Memory* (LSTM) yang mampu mempelajari pola serta dinamika data historis kunjungan.

D. Batasan Masalah

Agar ruang lingkup penelitian lebih jelas dan proses analisis dapat dilakukan secara terarah, penelitian ini dibatasi pada beberapa aspek berikut.

1. Penelitian ini hanya memanfaatkan data historis jumlah kunjungan Museum Airlangga sebagai sumber data, tanpa menggunakan data yang berasal dari museum lain.
2. Variabel yang digunakan dalam model prediksi terbatas pada jumlah kunjungan dan variabel eksternal seperti cuaca, kalender, atau *event* lokal hanya ditambahkan jika datanya tersedia dan relevan
3. Algoritma utama yang digunakan adalah LSTM, sementara metode seperti ARIMA atau regresi hanya dipakai sebagai pembandingan
4. Evaluasi kinerja model prediksi hanya dilakukan menggunakan metrik MAE, RMSE, dan MAPE tanpa menggunakan metrik lainnya.
5. Sistem berbasis *web* yang dibuat hanya berfungsi untuk menampilkan hasil prediksi, dan tidak mencakup fitur lain seperti manajemen koleksi, tiket elektronik, atau transaksi pengunjung.

6. Kualitas hasil prediksi bergantung pada ketersediaan dan kelengkapan data dari pihak museum, sehingga keterbatasan data dapat memengaruhi akurasi model

E. Tujuan Penelitian

Penelitian ini bertujuan menghasilkan model prediksi jumlah kunjungan Museum Airlangga berbasis algoritma Long Short-Term Memory (LSTM) yang mampu mempelajari karakteristik data historis sehingga dapat menghasilkan prediksi yang lebih akurat.

F. Manfaat Penelitian

Hasil penelitian ini diharapkan dapat memberikan kontribusi yang bermanfaat bagi kalangan akademisi maupun praktisi.

a. Manfaat Teoritis

Penelitian ini diharapkan dapat memperkaya kajian ilmiah pada bidang *Data Mining*, *Machine Learning*, dan *Deep Learning*, khususnya melalui penerapan algoritma Long Short-Term Memory (LSTM) untuk permasalahan prediksi deret waktu. Di samping itu, penelitian ini dapat menjadi tambahan referensi ilmiah mengenai penerapan metode prediksi jumlah pengunjung di sektor pariwisata dan kebudayaan, khususnya di lingkungan museum. Penelitian ini juga menyediakan model serta pendekatan analitis yang dapat dijadikan acuan bagi peneliti selanjutnya, baik dalam pengembangan metode prediksi maupun dalam penerapan model prediksi ke dalam sistem informasi berbasis *web* sebagai bagian dari pengembangan penelitian selanjutnya.

b. Manfaat Praktis

Secara praktis, penelitian ini diharapkan membantu pengelola Museum Airlangga memperoleh informasi prediksi jumlah pengunjung yang lebih akurat sehingga dapat digunakan untuk perancangan operasional,

pengelolaan sumber daya, dan persiapan fasilitas museum. Melalui prototipe sistem berbasis *web*, penelitian ini juga menyediakan visualisasi prediksi yang memudahkan pihak museum memahami pola kunjungan tanpa harus melakukan analisis data secara manual. Selain itu, penelitian ini memastikan dukungan terhadap pengambilan keputusan berbasis data, sehingga kegiatan promosi, penyusunan anggaran, dan penyelenggaraan *event* dapat dilakukan dengan lebih terarah. Penelitian ini juga meningkatkan efektivitas pengelolaan kunjungan dengan membantu museum mengantisipasi potensi lonjakan pengunjung pada periode tertentu, seperti hari libur, musim wisata, atau *event* khusus.

LANDASAN TEORI

A. Teori dan Penelitian Terdahulu

1. Landasan Teori

a. Museum dan Data Kunjungan

Museum adalah institusi permanen yang berfungsi mengumpulkan, merawat, meneliti, menafsirkan, dan memamerkan warisan budaya dan alam untuk tujuan edukasi, penelitian, dan hiburan (INTERNATIONAL COUNCIL OF MUSEUMS (ICOM)-Statutes (n.d.)). Dalam konteks modern, museum tidak hanya menjadi ruang pelestarian sejarah, tetapi juga berperan sebagai ruang publik yang harus beradaptasi dengan perkembangan teknologi serta kebutuhan pengunjung.

19

Informasi mengenai jumlah kunjungan merupakan salah satu komponen penting dalam pengelolaan museum karena dapat digunakan untuk memahami karakteristik serta pola perilaku pengunjung. Melalui data tersebut, pengelola dapat mengetahui periode kunjungan yang paling ramai, serta pola musiman yang memengaruhi jumlah kedatangan (Yap et al., 2024). Museum yang memanfaatkan data kunjungan secara sistematis dapat meningkatkan efektivitas operasional, mulai dari penjadwalan petugas, pengaturan alur ruang pameran, hingga perencanaan promosi. Namun, sebagian besar museum di Indonesia termasuk Museum Airlangga masih mengandalkan pencatatan manual, sehingga data yang dihasilkan sering tidak terstandar, sulit dianalisis, dan berpotensi hilang (Puspasari et al., 2023).

55

b. *Data Mining*

Data mining merupakan proses mengekstraksi pola, hubungan, maupun informasi yang bernilai dari kumpulan data berukuran besar sehingga dapat menghasilkan pengetahuan baru yang mendukung proses pengambilan keputusan.. Proses ini tidak sekadar mencari angka atau

18

statistik dasar, tetapi juga menyingkap hubungan tersembunyi yang memberikan konteks lebih mendalam terhadap data. *Data mining* terdiri dari beberapa tahapan utama seperti pembersihan data, transformasi, pemodelan, dan evaluasi untuk memastikan bahwa data siap digunakan secara optimal (Maryoosh & Hussein, 2022). Kualitas *preprocessing* memiliki pengaruh langsung terhadap akurasi model pada berbagai aplikasi *data mining* (Papakyriakou & Barbounakis, 2022). Teknik data mining modern mampu menangani dataset berskala besar dan mengungkap pola *non-linear* yang sulit terlihat secara manual (Gheisari et al., 2023).

Data mining menjadi pondasi penting dalam penelitian prediksi jumlah pengunjung museum karena memungkinkan pengolahan data historis yang sering kali tidak lengkap, tidak konsisten, atau belum terstruktur dengan baik. Melalui proses *data cleaning, integration, dan transformation*, melalui tahapan tersebut, data yang semula belum terstruktur dapat dipersiapkan menjadi dataset yang layak digunakan dalam proses pelatihan berbagai model pembelajaran mesin (Tian et al., 2025). Teknik ini juga berperan penting dalam menemukan kecenderungan kunjungan yang tidak dapat diamati secara langsung dari data mentah, seperti tren musiman, fluktuasi mingguan, serta lonjakan kunjungan pada periode tertentu (Delclòs-Alió et al., 2022). Penelitian lain juga menunjukkan bahwa penerapan metode seperti *K-Means Clustering*, *Random Forest*, dan *Long Short-Term Memory (LSTM)* mampu meningkatkan ketepatan prediksi perilaku pengunjung hingga sekitar 90% ketika proses data mining diterapkan secara menyeluruh dan terintegrasi (Zhao et al., 2024).

c. Machine Learning

Machine Learning merupakan salah satu cabang dari kecerdasan buatan (*Artificial Intelligence*) yang memungkinkan komputer mempelajari pola dari data tanpa harus diprogram secara rinci

untuk setiap tugas bertujuan mengembangkan model yang mampu mempelajari pola berdasarkan data yang tersedia untuk menghasilkan prediksi maupun mendukung proses pengambilan keputusan tanpa harus diberi aturan secara langsung. Teknologi ini bekerja dengan menganalisis data secara berulang untuk menemukan pola-pola tersembunyi, sehingga kemampuan model menjadi semakin baik seiring bertambahnya data pelatihan. Keberhasilan *Machine Learning* ditentukan oleh seberapa baik kualitas data dan bagaimana data diproses sebelum pelatihan dilakukan (Zhou et al., 2020).

Dalam bidang prediksi kunjungan museum, penerapan *Machine Learning* memungkinkan proses pembelajaran dari data historis sehingga model mampu menghasilkan estimasi yang lebih akurat dibandingkan pendekatan konvensional. Penelitian ini menerapkan algoritma *Long Short-Term Memory* (LSTM) sebagai metode utama karena memiliki kemampuan dalam memproses data deret waktu melalui pembelajaran terhadap keterkaitan antarurutan data. Berbagai penelitian sebelumnya menunjukkan bahwa LSTM mampu mengenali pola musiman dan perubahan jumlah kunjungan wisatawan dengan tingkat ketepatan yang baik (Hsieh, 2021). Selain itu, metode ini tetap memberikan performa yang memadai meskipun data historis yang digunakan mengandung ketidaklengkapan atau variasi kualitas data (Fuad et al., 2023).

d. *Deep Learning*

Deep Learning merupakan pengembangan dari *Machine Learning* yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan (*deep neural networks*) untuk mempelajari hubungan yang kompleks dari data dalam jumlah besar, termasuk pola yang bersifat nonlinier. Salah satu keunggulan metode ini adalah kemampuannya membangun representasi fitur secara otomatis tanpa bergantung pada proses *feature engineering* secara manual. Dengan mekanisme tersebut, model dapat mempelajari karakteristik data secara lebih mendalam

sehingga sesuai digunakan untuk mengolah berbagai jenis data, seperti teks, citra, maupun data deret waktu (*time series*). Kemampuan dalam mengenali hubungan jangka panjang dan pola yang kompleks menjadikan *Deep Learning* banyak diterapkan pada berbagai permasalahan prediksi, termasuk peramalan deret waktu (*time series forecasting*) (Zhou et al., 2020).

Penelitian ini menerapkan algoritma *Long Short-Term Memory* (LSTM) sebagai model utama dalam proses prediksi. LSTM merupakan salah satu arsitektur jaringan *Deep Learning* yang dirancang untuk mengolah data berurutan (*sequential data*), khususnya data deret waktu. Berbeda dengan jaringan saraf konvensional, LSTM memiliki mekanisme memori yang memungkinkan model mempertahankan informasi penting dari periode sebelumnya sehingga hubungan antardata dalam jangka panjang tetap dapat dipelajari. Karakteristik tersebut menjadikan LSTM sangat sesuai untuk memprediksi jumlah kunjungan museum karena mampu mengenali pola musiman, tren historis, serta perubahan jumlah pengunjung yang terjadi dari waktu ke waktu.

e. *Time Series Forecasting*

Time series merupakan sekumpulan data yang dicatat secara kronologis berdasarkan urutan waktu, misalnya per hari, minggu, bulan, ataupun tahun. Karakteristik utama data ini adalah adanya hubungan antarnilai pada setiap periode sehingga informasi pada masa lalu dapat dimanfaatkan untuk memperkirakan kondisi pada waktu yang akan datang. Analisis *time series* bertujuan memahami pola perubahan data, mengenali kecenderungan yang muncul, serta menghasilkan prediksi melalui pendekatan statistik maupun algoritma pembelajaran mesin.

Secara umum, data *time series* terdiri atas beberapa komponen, yaitu *trend*, *seasonality*, *cycle*, dan *noise*. *Trend* menunjukkan kecenderungan perubahan data dalam jangka panjang, baik meningkat

maupun menurun. *Seasonality* menggambarkan pola yang muncul secara berulang pada periode tertentu, misalnya setiap minggu atau musim tertentu. *Cycle* merupakan fluktuasi jangka panjang yang tidak terjadi secara tetap, sedangkan *noise* adalah variasi acak yang sulit diprediksi. Dalam konteks museum, pola kunjungan dapat dipengaruhi oleh berbagai kondisi, seperti hari libur nasional, musim wisata, maupun penyelenggaraan kegiatan atau pameran khusus (Fatima & Rahimi, 2024).

63
f. *Autoregressive Integrated Moving Average (ARIMA)*

ARIMA merupakan metode statistik yang banyak digunakan untuk menganalisis sekaligus melakukan peramalan terhadap data deret waktu. Pendekatan ini bekerja dengan memanfaatkan pola historis pada data yang bersifat linear dan umumnya memerlukan kondisi data yang stasioner. Model ARIMA tersusun atas tiga komponen utama, yaitu *Autoregressive (AR)* yang memanfaatkan nilai pada periode sebelumnya, 68 *Integrated (I)* yang berfungsi mengatasi ketidakstasioneran melalui proses *differencing*, serta *Moving Average (MA)* yang memodelkan hubungan berdasarkan kesalahan prediksi pada periode sebelumnya.

Namun, berbagai penelitian terbaru menunjukkan bahwa performa ARIMA cenderung menurun ketika diterapkan pada data yang bersifat nonlinier, berfluktuasi, serta dipengaruhi oleh banyak faktor eksternal. Pada data kunjungan wisata, metode ini sering menghasilkan akurasi yang lebih rendah karena karakteristik datanya dipengaruhi oleh pola musiman, penyelenggaraan berbagai kegiatan, dan perubahan perilaku pengunjung yang tidak sepenuhnya mengikuti hubungan linear (Umam, 2023).

15
g. *Long Short-Term Memory (LSTM)*

Menurut (Sherstinsky, 2020), LSTM merupakan arsitektur yang dikembangkan dari *Recurrent Neural Network (RNN)* untuk

meningkatkan kemampuan dalam memproses data berurutan dengan tujuan mengurangi permasalahan *vanishing gradient* yang sering muncul pada proses pelatihan jaringan saraf berulang. Berbeda dengan RNN biasa, LSTM dilengkapi mekanisme memori internal (*cell state*) yang memungkinkan model mempertahankan, memperbarui, maupun mengabaikan informasi sesuai kebutuhan proses pembelajaran agar lebih stabil, sehingga dapat menangkap pola jangka panjang serta hubungan temporal yang kompleks. Kemampuan ini menjadikan LSTM mampu mempertahankan ketergantungan jangka panjang maupun hubungan antarurutan data yang kompleks. Kemampuan ini menjadikannya sangat efektif untuk berbagai tugas *time-series forecasting*, termasuk memprediksi jumlah pengunjung museum yang memiliki pola naik-turun, musiman, dan fluktuatif dari waktu ke waktu. Dalam proses kerjanya, LSTM mengelola aliran informasi melalui tiga komponen pengendali utama, yaitu *forget gate*, *input gate*, dan *output gate*. Ketiga mekanisme tersebut mengatur aliran informasi dengan menentukan data yang dipertahankan, informasi baru yang dimasukkan, serta informasi yang diteruskan ke tahap berikutnya, dan masing-masing dirumuskan secara matematis sebagai berikut:

11

1) Forget Gate

Forget gate memiliki fungsi untuk menentukan seberapa banyak informasi dari waktu sebelumnya yang masih perlu dipertahankan dan apa saja yang harus diabaikan. Pada data kunjungan museum yang cenderung fluktuatif, gerbang ini membantu LSTM menyaring pola lama yang sudah tidak relevan agar tidak mengganggu proses pembelajaran. Secara matematis, mekanisme *forget gate* dirumuskan sebagai berikut:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \dots \dots \dots (2.1)$$

Keterangan:

- f_t : nilai *forget gate* yang menentukan informasi lama yang perlu dipertahankan.
- σ : fungsi sigmoid yang mengubah nilai menjadi rentang 0–1.
- W_f : bobot pada *forget gate*.
- $[h_{t-1}, x_t]$: gabungan hidden state sebelumnya dan *input* saat ini.
- b_f : bias pada *forget gate*.

2) Input Gate

Input gate berfungsi untuk mengatur informasi baru apa saja yang perlu disimpan di dalam memori LSTM. Dalam konteks prediksi kunjungan museum, gerbang ini membantu menentukan seberapa besar perubahan pada data historis yang layak dicatat sebagai pola baru agar model dapat belajar dengan lebih akurat. Secara matematis, mekanisme *Input gate* dirumuskan sebagai berikut:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \dots \dots \dots (2.2)$$

Keterangan:

- i_t : nilai *input gate* yang menentukan seberapa besar informasi baru akan disimpan.
- σ : fungsi aktivasi sigmoid untuk menghasilkan nilai antara 0–1.
- W_i : bobot pada *input gate*.
- $[h_{t-1}, x_t]$: gabungan *hidden state* sebelumnya dan *input* saat ini.
- b_i : bias pada *input gate*.

3) Candidate State (New Memory Content)

Kandidat memori baru berisi informasi tambahan yang berpotensi dimasukkan ke dalam *cell state*. Komponen ini membantu LSTM membentuk representasi baru dari pola jumlah pengunjung, terutama ketika muncul perubahan atau variasi yang perlu dipelajari dari data historis. Secara matematis, kandidat memori baru dirumuskan sebagai berikut:

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \dots \dots \dots (2.3)$$

Keterangan:

- $\tilde{C}_t$: kandidat nilai memori baru yang diusulkan untuk ditambahkan ke cell state.
- $\tanh$: fungsi aktivasi yang menghasilkan nilai antara -1 dan 1.
- W_c : bobot pada kandidat memori.
- $[h_{t-1}, x_t]$: gabungan hidden state sebelumnya dan input saat ini.
- b_c : bias pada perhitungan kandidat memori.

4) Cell State Update

Cell State digunakan untuk memperbarui memori jangka panjang yang dimiliki oleh LSTM. Cell state juga berperan sebagai penyimpan informasi utama dan membantu model mengingat pola kunjungan museum dari waktu ke waktu mulai dari tren naik dan turun, pola musiman, hingga lonjakan pengunjung saat ada acara tertentu. Pembaruan cell state dirumuskan sebagai berikut:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \dots \dots \dots (2.4)$$

Keterangan:

- C_t : cell state yang diperbarui pada waktu ke-t.
- $f_t * C_{t-1}$: bagian informasi lama yang dipertahankan.
- $i_t * \tilde{C}_t$: informasi baru yang ditambahkan ke memori.

5) Output Gate

Output gate berfungsi untuk memilih informasi mana dari cell state yang akan digunakan sebagai output pada waktu tertentu. Dengan kata lain, gerbang ini menentukan bagian memori yang paling relevan untuk menghasilkan prediksi pada timestep tersebut.

$$\sigma_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \dots \dots \dots (2.5)$$

Keterangan:

- σ_t : nilai output gate pada waktu ke-t.
- σ : fungsi sigmoid yang menghasilkan nilai 0-1.
- W_o : bobot pada output gate.

- d. $[h_{t-1}, x_t]$: gabungan hidden state sebelumnya dan *input* saat ini.
- e. b_o : bias pada *output gate*.

6) Hidden State

Hidden state merupakan output utama yang dihasilkan LSTM pada setiap *timestep*. Nilai inilah yang nantinya digunakan sebagai dasar untuk melakukan prediksi pada waktu berikutnya, termasuk dalam memprediksi jumlah pengunjung museum. *Hidden state* menggambarkan informasi yang telah diproses dan dianggap paling relevan.

$$h_t = o_t * \tanh(C_t) \dots \dots \dots (2.6)$$

Keterangan:

- a. h_t : *hidden state* pada waktu ke- t , sekaligus output LSTM.
- b. o_t : nilai dari *output gate*.
- c. $\tanh(C_t)$: aktivasi dari cell state yang telah diperbarui.

h. Evaluasi Model

Evaluasi model prediksi dilakukan untuk menilai sejauh mana hasil prediksi mendekati data aktual. Dalam penelitian deret waktu, khususnya pada kasus peramalan jumlah pengunjung atau tamu, metrik seperti MAE, RMSE, dan MAPE banyak digunakan karena mampu menunjukkan tingkat kesalahan model secara jelas dan mudah diinterpretasikan. Penggunaan metrik evaluasi ini juga terlihat pada penelitian prediksi kunjungan tamu hotel berbasis *Deep Learning*, di mana model dinilai menggunakan RMSE untuk mengukur akurasi prediksi terhadap data kunjungan yang bersifat fluktuatif (Satrani et al., 2025).

1) Mean Absolute Error (MAE)

MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual. Metrik ini memberi gambaran langsung tentang seberapa besar kesalahan model tanpa memperhitungkan arah kesalahan (lebih tinggi atau lebih rendah).

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \dots \dots \dots (2.6)$$

Keterangan:

- a. y_t = nilai aktual kunjungan pada waktu ke-t.
- b. $\hat{y}_t$ = nilai prediksi.
- c. Semakin kecil MAE maka semakin akurat model.
- d. Interpretasinya mudah karena satuannya sama seperti data asli (jumlah pengunjung).

2) Root Mean Square Error (RMSE)

RMSE mengukur kesalahan prediksi dengan memberi penalti lebih besar pada error yang ekstrem (selisih yang jauh lebih besar dari rata-rata). Karena menggunakan kuadrat error, metrik ini sensitif terhadap lonjakan atau fluktuasi data.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \dots \dots \dots (2.7)$$

Keterangan:

- a. Memperkuat pengaruh kesalahan yang besar.
- b. Cocok digunakan pada data kunjungan museum yang fluktuatif atau dipengaruhi *event* tertentu.
- c. Nilai lebih kecil berarti performa model lebih baik.

3) Mean Absolute Percentage Error (MAPE)

MAPE menunjukkan tingkat kesalahan model dalam bentuk persentase. Metrik ini mudah dipahami karena menunjukkan seberapa besar kesalahan relatif dibanding nilai aslinya.

$$MAPE = \sqrt{\frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|} \dots \dots \dots (2.8)$$

Keterangan:

- a. Menghasilkan nilai dalam persentase (%).

- b. Memudahkan interpretasi dalam konteks praktis (misalnya, “model memiliki *error* 8%”).
- c. Sensitif jika nilai aktual sangat kecil (mendekati nol).

i. *Flask*

Flask adalah *framework* pengembangan aplikasi berbasis *Python* yang termasuk ke dalam kelompok *micro-framework* karena menyediakan komponen inti yang sederhana dan ringan. *Flask* banyak dimanfaatkan dalam pengembangan aplikasi *web* karena memiliki arsitektur yang sederhana, ringan, serta mudah disesuaikan dengan kebutuhan pengembang. Berbeda dengan *framework* yang lebih besar, *Flask* hanya menyediakan fungsi-fungsi inti sehingga fitur tambahan, seperti pengelolaan basis data maupun validasi formulir, dapat dipasang melalui berbagai ekstensi sesuai kebutuhan aplikasi. Fleksibilitas tersebut menjadikan *Flask* banyak dipilih sebagai kerangka kerja dalam pembangunan berbagai sistem informasi berbasis web.

Penggunaan *Flask* memudahkan proses pengembangan aplikasi karena struktur proyek yang lebih rapi, mudah dipelihara, dan efisien untuk dikembangkan lebih lanjut. Selain itu, sintaks *Python* yang mudah dipahami membantu pengembang mempercepat proses implementasi sekaligus mempermudah pemeliharaan kode program. Pada penelitian ini, *Flask* digunakan untuk membangun Sistem Informasi Perantara Bisnis yang dapat membantu supplier dalam mengelola laporan pembelian dan tagihan secara lebih cepat, akurat, dan efisien dibandingkan proses manual. Selain itu, *Flask* dinilai mampu memberikan hasil aplikasi yang optimal sesuai kebutuhan pengguna karena sifatnya yang sederhana namun tetap fleksibel untuk dikembangkan. (Tamariska Bota & Setiyawati, 2022)

45

j. *Python*

Python merupakan bahasa pemrograman tingkat tinggi (*high-level programming language*) yang dirancang dengan sintaks yang

ringkas dan mudah dibaca, sehingga banyak digunakan oleh pengembang pemula maupun profesional. *Python* dirancang dengan filosofi “readability counts” yang berarti kode program dibuat agar mudah dibaca seperti bahasa manusia. Karena penulisannya lebih ringkas dibanding bahasa pemrograman lain, *Python* membantu pengguna memahami logika pemrograman secara lebih mudah, cepat, dan efisien. Selain itu, *Python* juga banyak dimanfaatkan pada berbagai bidang, seperti analisis data, kecerdasan buatan (*Artificial Intelligence*), *Machine Learning*, *Deep Learning*, serta pengembangan aplikasi berbasis web.

Selain menawarkan sintaks yang sederhana dan mudah dipahami, *Python* juga didukung oleh dokumentasi yang lengkap, komunitas yang besar, serta banyak library yang membantu proses pengembangan aplikasi menjadi lebih cepat. Dalam penerapannya, *Python* sering digunakan untuk data science, machine learning, automasi, scripting, hingga web development menggunakan framework seperti Django dan Flask. (Farhan Harahap et al., 2025)

k. Tensorflow dan Keras

TensorFlow merupakan framework sumber terbuka (*open-source*) yang dikembangkan untuk membangun, melatih, dan menjalankan model *Deep Learning* secara efisien. *TensorFlow* digunakan karena mampu mengelola proses training data secara efisien sehingga model yang dihasilkan dapat digunakan untuk berbagai kebutuhan, seperti klasifikasi, deteksi objek, pengenalan citra, maupun prediksi berbasis data. Dalam penelitian tersebut, *TensorFlow* dimanfaatkan untuk membangun sistem deteksi masker secara *realtime* menggunakan metode *Convolutional Neural Network* (CNN).

Keras digunakan sebagai library pendukung dalam framework *TensorFlow* untuk mempermudah proses pembuatan model *deep learning*. Keras membantu peneliti dalam menyusun model, melakukan

training data, serta menguji performa sistem dengan sintaks yang lebih sederhana dan mudah dipahami. Penggunaan *TensorFlow* dan Keras dalam penelitian ini dinilai mampu membantu pengembangan sistem deteksi masker menjadi lebih efektif, cepat, dan menghasilkan tingkat akurasi yang baik dalam proses pengenalan wajah secara realtime.(Sitorus, 2022)

2. Kajian Pustaka

Berdasarkan hasil tinjauan literatur yang bertujuan mengidentifikasi kesenjangan penelitian, beberapa artikel terdahulu dipilih sebagai dasar dalam pengembangan sistem prediksi jumlah pengunjung Museum Airlangga. Kajian ini berfokus pada penggunaan algoritma *Long Short-Term Memory* (LSTM) dalam pemodelan data deret waktu, yang terbukti mampu mengenali pola kunjungan dengan performa prediksi yang lebih baik pada data yang bersifat dinamis dan musiman. Penelitian oleh (Sherstinsky, 2020) membahas secara komprehensif mekanisme matematis dan keunggulan LSTM dalam menangani permasalahan *vanishing gradient* pada data berurutan. Dalam kajiannya, dijelaskan bahwa keberadaan *cell state* dan mekanisme gerbang pad LSTM memungkinkan pemeliharaan informasi jangka panjang secara stabil. Secara konseptual, temuan ini memperkuat dasar penggunaan LSTM pada prediksi kunjungan museum yang memiliki pola temporal jangka panjang dan fluktuasi yang tidak menentu.

Penelitian selanjutnya oleh (Hsieh, 2021) mengkaji penerapan LSTM dalam *tourism demand forecasting* dengan membandingkannya terhadap metode statistik tradisional. Hasil penelitian menunjukkan bahwa LSTM mampu memberikan performa yang lebih baik pada data yang dipengaruhi oleh faktor musiman dan tren jangka panjang. Studi ini menegaskan bahwa karakteristik data pariwisata, termasuk kunjungan museum, memiliki kemiripan dengan data permintaan wisata yang

dianalisis, sehingga pendekatan LSTM dinilai relevan untuk diterapkan dalam konteks penelitian ini.

Penelitian lain yang mendukung penggunaan LSTM pada data pariwisata dilakukan oleh (Fuad et al., 2023) yang meneliti prediksi kunjungan wisatawan menggunakan data *time series* yang tidak sepenuhnya konsisten. Penelitian ini menunjukkan bahwa LSTM tetap mampu menghasilkan prediksi yang stabil meskipun data memiliki nilai hilang dan pencatatan yang tidak seragam. Temuan ini menjadi relevan karena kondisi pencatatan data kunjungan museum sering kali masih dilakukan secara manual dan berpotensi memiliki ketidakteraturan serupa.

Penelitian lain yang relevan juga dilakukan oleh (Afnidia & Putri, 2025) yang berjudul “Prediksi Kunjungan Wisatawan Nusantara dan Mancanegara Menggunakan Metode *Long Short-Term Memory* (LSTM)”. Penelitian tersebut membahas permasalahan fluktuasi jumlah kunjungan wisatawan yang dipengaruhi oleh faktor musiman dan tren jangka panjang, sehingga sulit diprediksi menggunakan metode konvensional. Untuk mengatasi permasalahan tersebut, peneliti menerapkan algoritma LSTM pada data deret waktu kunjungan wisatawan nusantara dan mancanegara. Hasil penelitian menunjukkan bahwa LSTM mampu mempelajari pola temporal secara lebih baik serta menghasilkan nilai kesalahan prediksi yang relatif rendah. Temuan ini menunjukkan bahwa LSTM efektif digunakan pada data kunjungan wisata yang bersifat tidak linear dan dinamis. Namun, penelitian tersebut masih berfokus pada data kunjungan wisata secara umum, sehingga berbeda dengan penelitian ini yang secara khusus mengkaji prediksi jumlah pengunjung museum sebagai dasar perencanaan pengelolaan dan pengambilan keputusan operasional.

Dari sisi evaluasi model, penelitian oleh (Satrani et al., 2025) yang membahas prediksi kunjungan tamu hotel menekankan penggunaan metrik MAE dan RMSE sebagai indikator kinerja model. Menyatakan bahwa RMSE efektif dalam mendeteksi kesalahan besar pada data yang fluktuatif, sedangkan MAE memberikan gambaran rata-rata kesalahan yang lebih

stabil. Pendekatan evaluasi ini sejalan dengan penelitian ini yang menggunakan MAE, RMSE, dan MAPE untuk menilai performa model LSTM dalam memprediksi jumlah pengunjung museum.


Sebagai penguat dari sisi penelitian internal, studi oleh (Abadi et al., 2025) yang dipublikasikan pada Prosiding SEMNAS INOTEK mengkaji peramalan kebutuhan saldo berbasis data time series menggunakan LSTM. Penelitian ini menunjukkan bahwa LSTM mampu mengenali pola tren dengan baik pada data yang bersifat fluktuatif dan menghasilkan nilai *error* yang relatif rendah. Meskipun objek penelitian berbeda, ada kesamaan pada jenis data deret waktu dan pendekatan algoritma menjadikan penelitian ini relevan sebagai landasan metodologis bagi prediksi kunjungan Museum Airlangga.

Berdasarkan keseluruhan penelitian terdahulu, dapat disimpulkan bahwa LSTM merupakan metode yang telah terbukti efektif dalam memodelkan data *time series* yang bersifat *non-linear*, musiman, dan fluktuatif. Namun, sebagian besar penelitian sebelumnya masih berfokus pada sektor pariwisata umum, hotel, atau layanan digital, dan belum secara spesifik membahas prediksi kunjungan museum di Indonesia dengan keterbatasan data historis. Sehingga penelitian ini menempati posisi strategis dalam mengisi celah penelitian dengan menerapkan LSTM pada konteks museum serta mengevaluasi performanya menggunakan metrik standar peramalan deret waktu.

B. Kerangka Berfikir

Kerangka berpikir penelitian ini disusun untuk menjelaskan alur penelitian secara ringkas dan sistematis. Penelitian diawali dari identifikasi masalah di Museum Airlangga, yaitu belum adanya sistem prediksi jumlah pengunjung yang mampu memanfaatkan data historis secara optimal. Data kunjungan yang tersedia cenderung berubah-ubah dan dipengaruhi pola musiman, namun belum digunakan secara maksimal dalam pengambilan keputusan. Selanjutnya, penelitian didukung oleh landasan teori dan kajian

pustaka untuk menemukan celah penelitian dan merumuskan solusi yang sesuai. Alur tersebut divisualisasikan pada Diagram 2.1.



Gambar 2. 1 Kerangka Berfikir

Berdasarkan permasalahan yang ada, penelitian ini disusun dengan berlandaskan pada landasan teori yang relevan. Landasan teori meliputi konsep data deret waktu (*time series*) yang digunakan untuk menganalisis pola data

kunjungan dari waktu ke waktu, teori prediksi kunjungan wisata, serta penerapan *Machine Learning*, khususnya algoritma *Long Short-Term Memory* (LSTM) yang mampu menangkap pola jangka pendek dan jangka panjang dalam data. Selain itu, digunakan pula teori mengenai evaluasi model dengan metrik kesalahan seperti MAE, RMSE, dan MAPE untuk mengukur tingkat akurasi hasil prediksi.

Landasan teori tersebut diperkuat melalui kajian pustaka dari berbagai penelitian terdahulu yang membahas peramalan permintaan wisata dan kunjungan menggunakan metode LSTM maupun perbandingannya dengan metode lain seperti ARIMA. Hasil kajian pustaka menunjukkan bahwa LSTM memiliki keunggulan dalam memodelkan data time series yang bersifat nonlinier dan musiman, sehingga relevan untuk diterapkan pada kasus prediksi jumlah pengunjung museum.

Selanjutnya, berdasarkan permasalahan dan kajian teori yang ada, dirumuskan usulan penyelesaian masalah, yaitu merancang model prediksi jumlah pengunjung Museum Airlangga menggunakan algoritma LSTM. Data kunjungan historis akan dibagi menjadi data latih dan data uji, kemudian diproses melalui tahapan preprocessing dan sliding window. Model yang dibangun akan diuji kinerjanya menggunakan metrik MAE, RMSE, dan MAPE untuk menilai tingkat akurasi prediksi yang dihasilkan.

Harapan dari penelitian ini adalah hasil prediksi jumlah pengunjung museum dapat memberikan gambaran yang lebih akurat mengenai pola kunjungan berdasarkan data historis. Informasi ini diharapkan dapat menjadi bahan pertimbangan bagi pengelola museum dalam memahami tren kunjungan, meningkatkan efisiensi pengelolaan sumber daya, serta mendukung perencanaan operasional yang lebih efektif dan berbasis data.

METODE PENELITIAN

A. Desain Penelitian

Desain penelitian berfungsi sebagai kerangka kerja yang memberikan arah dan struktur yang jelas dalam pelaksanaan penelitian, sehingga setiap tahapan dapat dilakukan secara sistematis dan terencana. Dengan adanya desain penelitian yang matang, proses penelitian dapat berjalan secara terkontrol, konsisten, dan sesuai dengan tujuan yang telah ditetapkan. Berbagai komponen yang terdapat dalam desain penelitian digunakan sebagai pedoman untuk mengarahkan langkah-langkah penelitian agar pelaksanaannya efektif, efisien, serta memiliki validitas dan kejelasan metodologis. Komponen-komponen tersebut terdiri dari:

127

1. Jenis Penelitian (*Research Type*)

Penelitian ini menggunakan metodologi Penelitian Pengembangan (*Development Research*) karena bertujuan merancang dan membangun sistem prediksi jumlah pengunjung museum berbasis algoritma *Long Short-Term Memory* (LSTM). Desain penelitian ini dipilih karena fokus penelitian tidak hanya pada analisis data historis, tetapi juga mencakup proses perancangan sistem, pembangunan model prediksi, pelatihan, serta pengujian kinerja sistem secara menyeluruh.

Sistem yang dirancang diharapkan mampu memberikan solusi terhadap permasalahan prediksi jumlah pengunjung museum yang selama ini masih dilakukan secara sederhana dan belum mempertimbangkan pola temporal jangka panjang, seperti tren, fluktuasi, dan pola musiman. Dengan memanfaatkan kemampuan LSTM dalam mempelajari hubungan temporal yang kompleks, sistem prediksi yang dibangun diharapkan mampu menghasilkan estimasi jumlah pengunjung yang lebih akurat, konsisten, dan adaptif terhadap perubahan pola kunjungan dari waktu ke waktu, sehingga dapat mendukung proses perencanaan dan pengambilan keputusan pengelola museum menjadi lebih efektif.

2. Variabel Penelitian

a. Variabel Independen (Bebas/Prediktor)

Variabel independen dalam penelitian ini meliputi penggunaan algoritma *Long Short-Term Memory* (LSTM) sebagai model utama dalam memprediksi jumlah pengunjung berdasarkan data deret waktu. Variabel ini juga mencakup faktor-faktor teknis yang berkaitan dengan proses pemodelan, seperti panjang jendela waktu (*time step*), jumlah *neuron* pada lapisan tersembunyi, jumlah *epoch*, ukuran *batch*, serta nilai *learning rate* yang digunakan selama pelatihan model. Selain itu, jumlah dan rentang data historis pengunjung yang digunakan sebagai data latih juga termasuk dalam variabel independen, karena seluruh parameter tersebut berpotensi memengaruhi kemampuan model dalam mempelajari pola kunjungan dan menghasilkan prediksi yang akurat.

b. Variabel Dependen (Terikat / Respon)

Variabel dependen dalam penelitian ini adalah hasil prediksi jumlah pengunjung museum yang dihasilkan oleh model *Long Short-Term Memory* (LSTM). Variabel ini merepresentasikan keluaran utama dari proses pemodelan dan digunakan untuk menilai tingkat keberhasilan model dalam mempelajari pola kunjungan berdasarkan data historis. Selain itu, tingkat kesalahan prediksi yang diukur menggunakan metrik evaluasi seperti *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) juga termasuk dalam variabel dependen, karena nilai-nilai tersebut secara langsung mencerminkan akurasi dan performa model prediksi yang dibangun.

c. Variabel Kontrol

Variabel kontrol dalam penelitian ini merupakan faktor-faktor yang dijaga tetap konstan selama proses penelitian untuk memastikan validitas hasil eksperimen. Variabel kontrol tersebut meliputi sumber data pengunjung, periode waktu data yang digunakan, serta proses pra-pemrosesan data seperti normalisasi dan pembagian data latih dan data uji.

Selain itu, lingkungan pengujian, termasuk perangkat keras yang digunakan, bahasa pemrograman, pustaka *Deep Learning*, serta konfigurasi sistem operasi juga ditetapkan secara tetap. Pengendalian terhadap variabel-variabel ini dilakukan agar perubahan hasil prediksi yang diperoleh benar-benar disebabkan oleh konfigurasi model LSTM, bukan oleh faktor eksternal lainnya.

3. Metode Pengumpulan Data

Metode pengumpulan data dalam penelitian ini dilakukan dengan menggunakan data sekunder, yaitu data yang telah tersedia dan dicatat oleh pihak pengelola museum. Data yang digunakan berupa data historis jumlah pengunjung Museum Airlangga yang dicatat secara berkala dalam rentang waktu tertentu. Data ini diperoleh dari arsip administrasi atau sistem pencatatan kunjungan yang dimiliki oleh pihak museum dan digunakan sebagai dasar dalam proses pemodelan dan prediksi. Pengumpulan data dilakukan melalui studi dokumentasi, dengan cara mengumpulkan, menyeleksi, dan mengarsipkan data kunjungan yang relevan dengan kebutuhan penelitian. Data yang diperoleh kemudian diperiksa kelengkapannya untuk memastikan kesesuaian format, konsistensi waktu pencatatan, serta keberlanjutan data deret waktu. Tahap ini penting untuk menjamin bahwa data yang digunakan layak diolah dalam model prediksi berbasis *Long Short-Term Memory* (LSTM).

Studi literatur juga dilakukan sebagai bagian dari metode pengumpulan data pendukung. Studi literatur bertujuan untuk memperoleh referensi ilmiah terkait prediksi deret waktu, penggunaan algoritma LSTM, serta metode evaluasi model prediksi yang relevan. Literatur yang digunakan berasal dari jurnal ilmiah, prosiding, dan buku referensi bereputasi dalam lima tahun terakhir, sehingga dapat memperkuat landasan teori dan metodologi penelitian. Data yang telah terkumpul selanjutnya digunakan pada tahap pra-pemrosesan, pelatihan model, dan evaluasi performa prediksi sesuai dengan rancangan penelitian yang telah ditetapkan.

B. Instrumen Penelitian

Penelitian ini melibatkan beberapa instrumen yang terdiri dari perangkat keras, perangkat lunak, *dataset*, serta analisis hasil, di mana setiap bagian memiliki peranan penting dalam proses pengumpulan data, pemrosesan data, pelatihan model, hingga evaluasi kinerja model prediksi. Instrumen-instrumen tersebut digunakan secara terintegrasi untuk mendukung keberhasilan penelitian. Adapun rincian instrumen penelitian adalah sebagai berikut:

1. Perangkat Keras

- a. Perangkat keras yang digunakan dalam penelitian ini berupa sebuah komputer atau laptop dengan spesifikasi minimal prosesor setara Intel Core i5 atau AMD Ryzen 5, RAM 8 GB, media penyimpanan SSD 256 GB, serta kartu grafis terintegrasi yang mendukung komputasi dasar.
- b. Perangkat keras ini digunakan untuk menjalankan proses pemrosesan data, pelatihan model *Long Short-Term Memory* (LSTM), serta pengujian dan evaluasi hasil prediksi.
- c. Spesifikasi perangkat keras dijaga konsisten selama penelitian untuk memastikan stabilitas proses pelatihan dan keandalan hasil eksperimen.

2. Perangkat Lunak

- a. Sistem operasi yang digunakan dalam penelitian ini adalah *Windows 10* atau *Windows 11* sebagai lingkungan utama pengembangan dan pengujian model.
- b. Bahasa pemrograman yang digunakan adalah *Python* versi 3.11.9, yang dimanfaatkan untuk proses pra-pemrosesan data, pembentukan data *time series*, pelatihan model LSTM, hingga evaluasi hasil prediksi.
- c. *Library* dan *framework* yang digunakan meliputi *TensorFlow/Keras* untuk implementasi dan pelatihan model LSTM, *NumPy* dan *Pandas* untuk pengolahan data numerik dan deret waktu.
- d. *Integrated Development Environment* (IDE) dan *tools* yang digunakan antara lain *Jupyter Notebook*, *Google Colab*, atau *Visual Studio Code* untuk menulis, menjalankan, dan mengelola kode program penelitian.

3. Dataset

Dataset yang digunakan dalam penelitian ini berupa data historis jumlah pengunjung Museum Airlangga yang diperoleh dari arsip atau catatan resmi pengelola museum. Data tersebut disusun dalam bentuk deret waktu dengan interval tertentu, seperti harian atau bulanan. Dataset yang telah terkumpul kemudian dibagi menjadi data pelatihan (*training*) dan data pengujian (*testing*) untuk membangun dan mengevaluasi model prediksi. Sebelum digunakan, data melalui tahap pra-pemrosesan seperti pembersihan data, normalisasi, serta pembentukan *input* menggunakan metode *sliding window* agar sesuai dengan kebutuhan model LSTM.

4. Analisis Hasil

Analisis hasil dilakukan untuk menilai kinerja model prediksi yang telah dibangun. Evaluasi model dilakukan menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) untuk mengukur tingkat kesalahan antara data aktual dan hasil prediksi. Selain itu, analisis visual berupa perbandingan grafik antara nilai aktual dan nilai prediksi juga digunakan untuk melihat kemampuan model dalam menangkap pola kunjungan museum yang bersifat fluktuatif dan musiman.

C. Tempat dan Jadwal Penelitian

Penelitian ini dilaksanakan di Museum Airlangga Kota Kediri karena merupakan fokus utama riset ini, yaitu merancang sistem untuk memprediksi jumlah kunjungan. Dengan fokus utamanya adalah membantu pihak museum dalam merencanakan langkah operasional secara lebih terukur dan berbasis data. Urutan kegiatan yang dilakukan dalam penelitian ini telah dirangkum dalam Tabel 3.1 berikut:

Tabel 3. 1 Jadwal Penelitian

No	Kegiatan	Waktu (Bulan/Minggu)																							
		Bulan ke-1				Bulan ke-2				Bulan ke-3				Bulan ke-4				Bulan ke-5				Bulan ke-6			
		1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
1	Studi Literatur																								
2	Pengumpulan Data																								
3	Analisis Sistem																								
4	Desain Sistem																								
5	Implementasi Model																								
6	Uji Coba dan Analisis Hasil																								
7	Penyusunan Laporan																								

D. Objek Penelitian/Subjek Penelitian

92

1. Analisis Kebutuhan Sistem

Analisis kebutuhan sistem pada penelitian ini dilakukan untuk mendefinisikan secara jelas tujuan dan ruang lingkup sistem prediksi jumlah pengunjung museum yang akan dibangun. Proses ini bertujuan untuk mengidentifikasi kebutuhan utama agar sistem mampu menyelesaikan permasalahan prediksi kunjungan secara efektif dan sesuai dengan kondisi data yang tersedia.

84

a. Kebutuhan Fungsional

Kebutuhan fungsional memiliki fungsi utama yang harus dimiliki oleh sistem prediksi jumlah pengunjung museum. Sistem dirancang agar mampu menerima dan mengolah data historis jumlah pengunjung yang berbentuk data deret waktu sebagai *input* utama. Kemudian sistem dapat melakukan proses pelatihan model prediksi menggunakan algoritma

Long Short-Term Memory (LSTM) untuk mempelajari pola kunjungan dari waktu ke waktu. Sistem juga harus mampu menghasilkan keluaran berupa prediksi jumlah pengunjung pada periode tertentu. Sistem juga menyediakan hasil evaluasi kinerja model prediksi menggunakan metrik *Mean Absolute Error (MAE)*, *Root Mean Square Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)* untuk mengetahui tingkat akurasi dan keandalan model yang dibangun.

b. Kebutuhan Non-Fungsional

Kebutuhan non-fungsional memiliki keterkaitan dengan kualitas sistem yang diharapkan dalam mendukung proses prediksi jumlah pengunjung museum. Sistem diharapkan memiliki kinerja yang stabil dalam memproses data historis serta menghasilkan hasil prediksi secara konsisten. Sistem juga dirancang agar mudah digunakan dan dipahami, termasuk oleh pengguna non-teknis, sehingga tidak memerlukan keahlian khusus dalam pengoperasiannya. Sistem juga mampu menampilkan hasil prediksi dan evaluasi model secara jelas, ringkas, dan informatif sehingga mudah dipahami dan dapat mendukung proses pengambilan keputusan.

c. Kebutuhan Data

Data yang digunakan dalam penelitian ini adalah data kunjungan pengunjung museum yang disajikan dalam bentuk data deret waktu (*time series*). Data ini mencerminkan jumlah pengunjung dalam rentang waktu tertentu, baik harian maupun bulanan, yang digunakan sebagai dasar dalam proses analisis dan pemodelan prediksi. Penggunaan data *time series* dipilih karena mampu merepresentasikan perubahan jumlah kunjungan dari waktu ke waktu serta memungkinkan identifikasi pola tren, fluktuasi, dan pola musiman yang terjadi secara berulang. Data historis yang digunakan mencakup periode minimal dua tahun. Rentang waktu tersebut dianggap memadai untuk menangkap karakteristik jangka pendek maupun jangka panjang dari pola kunjungan museum, sehingga

model prediksi yang dibangun dapat mempelajari hubungan temporal secara lebih optimal. Data dengan periode yang cukup panjang juga membantu meningkatkan stabilitas dan akurasi model dalam melakukan prediksi terhadap periode mendatang.

Jenis data yang digunakan dalam penelitian ini meliputi dua kategori utama. Pertama, data transaksi berupa jumlah kunjungan pengunjung museum pada setiap periode waktu tertentu, baik per hari maupun per bulan. Data ini menjadi data utama (*input*) dalam proses pelatihan dan pengujian model prediksi. Kedua, data analitik berupa hasil agregasi atau pengolahan lanjutan dari data kunjungan, yang digunakan untuk menganalisis tren, pola musiman, serta sebagai dasar dalam evaluasi kinerja model. Secara struktur, data yang digunakan berbentuk data terstruktur dalam format tabel numerik sehingga dapat diolah secara langsung menggunakan metode komputasi dan algoritma pembelajaran mesin. Namun, data yang diperoleh memungkinkan adanya ketidakkonsistenan, seperti data hilang (*missing value*) atau perbedaan pola pencatatan, yang disebabkan oleh proses pencatatan kunjungan yang masih dilakukan secara manual. Sehingga, sebelum digunakan dalam pemodelan, data terlebih dahulu melalui tahap pra-pemrosesan untuk memastikan kualitas data yang layak digunakan dalam proses pelatihan dan evaluasi model prediksi.

2. Objek Penelitian

Objek penelitian dalam penelitian ini adalah sistem prediksi jumlah pengunjung museum yang dirancang untuk mengolah data historis kunjungan dan menghasilkan prediksi jumlah pengunjung pada periode mendatang. Sistem ini dibangun sebagai prototipe penelitian yang berfungsi untuk melakukan pengolahan data deret waktu, pelatihan model prediksi, serta menampilkan hasil prediksi dan evaluasi model. Algoritma yang menjadi objek penelitian adalah *Long Short-Term Memory* (LSTM), yaitu salah satu metode *deep learning* yang digunakan untuk memodelkan data berurutan.

LSTM dipilih karena kemampuannya dalam mempelajari pola temporal jangka panjang pada data yang bersifat fluktuatif dan musiman, seperti data kunjungan museum.

Model prediksi berbasis LSTM yang dibangun dalam penelitian ini menjadi fokus analisis untuk menilai kemampuan model dalam menghasilkan prediksi yang akurat. Model dilatih menggunakan data historis kunjungan museum dan diuji performanya menggunakan metrik evaluasi MAE, RMSE, dan MAPE. Selain itu, objek penelitian juga mencakup data historis jumlah pengunjung museum berbentuk data time series dengan rentang waktu minimal tiga tahun. Data ini digunakan sebagai *input* utama dalam proses pelatihan dan pengujian model prediksi.


3. Subjek Penelitian

Subjek penelitian dalam penelitian ini adalah sumber data dan pihak yang menyediakan informasi yang diperlukan dalam proses perancangan, pelatihan, dan evaluasi sistem prediksi jumlah pengunjung museum. Subjek penelitian tidak melibatkan responden secara langsung, melainkan berfokus pada data dan sistem yang digunakan dalam penelitian. Subjek utama penelitian ini adalah data historis kunjungan Museum Airlangga yang berupa catatan jumlah pengunjung dalam periode waktu tertentu. Data ini digunakan sebagai sumber informasi utama untuk membangun dan menguji model prediksi berbasis *Long Short-Term Memory* (LSTM).

Subjek penelitian juga mencakup sistem prediksi yang dirancang dan diimplementasikan dalam penelitian ini. Sistem tersebut menghasilkan data log berupa hasil pelatihan model, nilai prediksi, serta hasil evaluasi kinerja model yang dianalisis lebih lanjut untuk menilai tingkat akurasi dan keandalan sistem. Dalam konteks teknis, perangkat lunak yang digunakan untuk proses pengolahan data dan pelatihan model juga menjadi bagian dari subjek penelitian, khususnya dalam kaitannya dengan performa sistem dalam menghasilkan prediksi.

E. Prosedur Penelitian

Untuk memastikan penelitian berjalan secara terarah dan sistematis, prosedur penelitian disusun dalam serangkaian tahapan kerja yang berurutan. Alur pelaksanaan penelitian ini, mulai dari studi literatur hingga penyusunan laporan akhir.



Gambar 3. 1 *Waterfall Diagram*

1. Studi Literatur

Tahap awal dalam proses penelitian ini diinisiasi melalui eksplorasi mendalam terhadap teori-teori dasar, metodologi-metodologi yang telah dikembangkan, serta kajian-kajian sebelumnya yang memiliki relevansi langsung dengan bidang prediksi data deret waktu (*time series*) dan penerapan algoritma *Long Short-Term Memory* (LSTM). Kajian literatur yang secara menyeluruh ini dirancang dengan tujuan utama untuk membangun fondasi teoritis yang kokoh dan tangguh, sekaligus untuk mengidentifikasi serta menganalisis celah-celah penelitian yang masih terbuka, sehingga memungkinkan pengembangan kajian lanjutan yang lebih inovatif dan terarah.

69

2. Pengumpulan Data

Pada tahapan ini, dilakukan proses pengumpulan data historis yang berkaitan dengan jumlah pengunjung Museum Airlangga secara sistematis dan menyeluruh. Data yang diperoleh berupa rangkaian data deret waktu (*time series*) yang mencakup periode minimal dua tahun, yang dipilih sebagai fondasi utama untuk mendukung kegiatan pemodelan matematis dan proses prediksi yang akurat serta konsisten dalam konteks penelitian ini.

3. Analisis Sistem

Pada tahap analisis ini memiliki berfungsi sebagai instrumen untuk merangkum berbagai kebutuhan teknis dan operasional, sehingga sistem prediksi yang dihasilkan mampu memberikan dukungan pengambilan keputusan yang berbasis data (*data-driven decision making*) bagi manajemen museum.

4. Desain Sistem

Tahap desain system mencakup perancangan sistem prediksi yang terkonsep, termasuk perancangan alur pemrosesan data, desain arsitektur model LSTM, serta perancangan output berupa hasil prediksi dan evaluasi model dalam mencapai tingkat presisi prediksi yang optimal.

5. Implementasi Sistem

Pada tahap implementasi, sistem prediksi direalisasikan dengan mengimplementasikan algoritma LSTM menggunakan data kunjungan museum. Proses ini meliputi pra-pemrosesan data, pelatihan model, dan pembuatan sistem prediksi.

85

6. Uji Coba dan Analisis Hasil

Tahap uji coba dilakukan untuk mengukur kinerja model prediksi menggunakan metrik evaluasi MAE, RMSE, dan MAPE. Hasil pengujian dianalisis untuk mengetahui tingkat akurasi dan keandalan model dalam memprediksi jumlah pengunjung museum.

20

7. Penyusunan Laporan

Tahap akhir penelitian adalah penyusunan laporan penelitian yang memuat seluruh proses, hasil analisis, pembahasan, kesimpulan, serta rekomendasi yang dihasilkan dari penelitian.

F. Teknik Analisis Data

Teknik analisis data diimplementasikan melalui perancangan sistem prediksi dengan pendekatan rekayasa perangkat lunak. Tahapan ini mencakup pengolahan data teknis, desain arsitektur, pemodelan logika, dan perancangan *interface* pengguna.

1) Desain Sistem


Desain system dirancang dengan arsitektur berbasis *web* agar admin museum dapat dengan mudah mengakses fitur prediksi jumlah pengunjung museum.

a. Arsitektur Sistem

Penelitian ini menggunakan pendekatan *Object-Oriented Analysis and Design* (OOAD) dalam perancangan sistem. Pendekatan ini dipilih karena sistem prediksi jumlah pengunjung museum merupakan kumpulan objek yang saling berinteraksi, mulai dari proses pengolahan data historis hingga menghasilkan output prediksi. Desain sistem dimodelkan menggunakan *Unified Modeling Language* (UML) untuk menggambarkan interaksi antara pengguna dan sistem serta alur proses yang terjadi di dalamnya. Penggunaan OOAD diharapkan mampu menghasilkan rancangan sistem yang terstruktur, mudah dipahami, dan mendukung proses implementasi sistem prediksi secara efektif.

52

1) Use Case Diagram



Gambar 3. 2 Use Case Diagram

Gambar 3.2 Use Case Diagram menggambarkan fungsi-fungsi utama sistem prediksi jumlah pengunjung museum dari sudut pandang pengguna. Diagram ini menekankan apa yang dapat dilakukan sistem tanpa membahas bagaimana proses internalnya dijalankan.

1. Admin Museum

Admin Museum merupakan satu-satunya aktor dalam sistem ini. Pemilihan satu aktor bertujuan untuk menyesuaikan dengan batasan masalah penelitian, di mana sistem hanya difokuskan pada pengelolaan dan analisis data prediksi, bukan sistem operasional museum secara keseluruhan. Admin Museum bertanggung jawab atas pengelolaan data dan pengambilan keputusan berdasarkan hasil prediksi.

2. Dashboard

Dashboard merupakan halaman utama sistem yang pertama kali ditampilkan ketika Admin Museum membuka aplikasi. Halaman ini berfungsi sebagai pusat navigasi untuk mengakses seluruh fitur yang tersedia pada sistem. Melalui dashboard, Admin Museum dapat menuju halaman data historis maupun halaman prediksi pengunjung dengan lebih mudah. Selain itu, dashboard

juga memberikan tampilan sistem yang lebih terstruktur dan memudahkan pengguna dalam mengoperasikan aplikasi.


3. Data Historis

Menu Data Historis digunakan untuk mengelola data pengunjung museum yang tersimpan di dalam *database*. Pada fitur ini, Admin Museum dapat melakukan beberapa aktivitas seperti menambahkan data pengunjung, mengubah data, menghapus data, serta melihat data historis pengunjung yang telah tersimpan. Data historis tersebut nantinya digunakan sebagai data utama dalam proses prediksi jumlah pengunjung museum menggunakan algoritma *Long Short-Term Memory (LSTM)*.

4. Prediksi

Menu Prediksi digunakan untuk melakukan proses prediksi jumlah pengunjung museum berdasarkan data historis yang telah tersedia. Pada halaman ini, sistem akan memproses data menggunakan algoritma *Long Short-Term Memory (LSTM)* untuk menghasilkan prediksi jumlah pengunjung pada periode berikutnya. Selain menampilkan hasil prediksi, sistem juga menampilkan hasil evaluasi model berupa nilai MAE, RMSE, dan MAPE untuk mengetahui tingkat akurasi model prediksi yang digunakan. Sistem juga menyediakan grafik hasil prediksi agar pengguna lebih mudah memahami pola data pengunjung museum.

2) Activity Diagram



Gambar 3.3 Activity Diagram

Gambar 3.3 Activity Diagram digunakan untuk menggambarkan alur aktivitas atau tahapan proses yang terjadi di dalam sistem secara berurutan sejak awal hingga akhir.

a. Admin Mengakses Sistem

Proses dimulai pada saat Admin Museum mengakses sistem prediksi. Aktivitas ini menandai interaksi awal antara pengguna dan sistem, di mana Admin bertindak sebagai pihak yang mengoperasikan sistem untuk melakukan analisis prediksi jumlah pengunjung.

b. Sistem Menampilkan Form *Input Data*

Setelah Admin mengakses sistem, sistem secara otomatis menampilkan form *input data*. Form ini digunakan sebagai media bagi Admin untuk memasukkan data historis jumlah pengunjung museum yang akan diproses lebih lanjut.

c. *Input Data* Historis Pengunjung

Pada tahap ini, Admin Museum memasukkan data historis pengunjung ke dalam sistem. Data yang dimasukkan berupa data

deret waktu (*time series*) yang mencerminkan jumlah pengunjung museum pada periode tertentu. Data ini menjadi *input* utama dalam proses prediksi.

d. *Preprocessing Data*

Tahap preprocessing merupakan proses internal sistem untuk menyiapkan data agar sesuai dengan kebutuhan algoritma LSTM. Proses ini meliputi pembersihan data, normalisasi (misalnya *Min-Max*), dan pembentukan struktur data *time series*. Tahap ini penting untuk mengurangi *noise* dan meningkatkan stabilitas model prediksi.

e. Proses Prediksi Jumlah Pengunjung

Data yang telah diproses selanjutnya digunakan oleh sistem untuk melakukan proses prediksi jumlah pengunjung. Pada tahap ini, sistem menjalankan algoritma *Long Short-Term Memory* (LSTM) untuk mempelajari pola kunjungan berdasarkan data historis dan menghasilkan prediksi jumlah pengunjung pada periode selanjutnya.

f. Evaluasi Prediksi (MAE, RMSE, MAPE)

Hasil prediksi yang dihasilkan kemudian dievaluasi menggunakan beberapa metrik evaluasi, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Tahap evaluasi ini bertujuan untuk mengukur tingkat kesalahan dan performa model prediksi yang digunakan.

g. Hasil Prediksi


Setelah proses evaluasi selesai, sistem menghasilkan output berupa hasil prediksi jumlah pengunjung beserta nilai evaluasinya. Output ini disiapkan untuk ditampilkan kepada pengguna sebagai informasi pendukung pengambilan keputusan.

h. Admin Melihat Hasil Prediksi

Pada tahap akhir, Admin Museum melihat hasil prediksi yang ditampilkan oleh sistem. Informasi ini dapat digunakan sebagai dasar dalam perencanaan operasional museum, seperti pengaturan jadwal, sumber daya, atau strategi pelayanan pengunjung.

i. Proses Selesai

Proses berakhir setelah Admin Museum menerima dan memahami hasil prediksi yang ditampilkan oleh sistem. Aktivitas ini menandai akhir dari alur kerja sistem prediksi jumlah pengunjung museum.



Gambar 3.4 Sequence Diagram

Gambar 3.4 Sequence Diagram ini menggambarkan alur interaksi antar aktor dan komponen sistem dalam proses prediksi jumlah pengunjung museum, mulai dari input data hingga penampilan hasil prediksi.

a. *inputData()*

Admin Museum → Sistem

Proses dimulai ketika Admin Museum memasukkan data historis jumlah pengunjung ke dalam sistem. Data yang dimasukkan berupa data deret waktu (*time series*) yang

merepresentasikan jumlah pengunjung museum pada periode tertentu. Fungsi *inputData()* berperan sebagai pintu masuk data ke dalam sistem sebelum dilakukan proses pengolahan lebih lanjut.

b. *traindanPredict()*

Sistem → Model Prediksi (LSTM)

Setelah data diterima, sistem memanggil fungsi *traindanPredict()* pada Model Prediksi (LSTM). Pemanggilan fungsi ini menandakan bahwa sistem meminta model untuk melakukan proses pelatihan dan prediksi berdasarkan data historis yang telah diberikan. Pada tahap ini, sistem berfungsi sebagai pengendali utama yang mengatur alur proses prediksi.

c. *praPemrosesanData()*

Sistem → Model Prediksi (LSTM) (pesan internal/pra-proses)

Sebelum data diproses oleh model LSTM, sistem melakukan pra-pemrosesan data melalui fungsi *praPemrosesanData()*. Tahapan ini meliputi proses normalisasi data, pembersihan data, serta pembentukan struktur data time series yang sesuai dengan kebutuhan algoritma LSTM. Pra-pemrosesan bertujuan untuk meningkatkan kualitas data sehingga hasil prediksi menjadi lebih akurat dan stabil.

d. *hasilPrediksi()*

Model Prediksi (LSTM) → Evaluasi Prediksi

Setelah proses pelatihan dan prediksi selesai, Model Prediksi (LSTM) menghasilkan nilai prediksi jumlah pengunjung. Hasil prediksi ini kemudian dikirim ke modul Evaluasi Prediksi melalui fungsi *hasilPrediksi()*. Tahap ini menandai berakhirnya proses pemodelan dan dimulainya proses evaluasi kinerja model.

e. *tampilkanHasil()*

Evaluasi Prediksi → Model Prediksi (LSTM)

Pada tahap ini, modul Evaluasi Prediksi menghitung nilai evaluasi model menggunakan metrik MAE, RMSE, dan MAPE.

Setelah perhitungan selesai, **hasil** evaluasi dikirim kembali ke model melalui fungsi `tampilkanHasil()`. Proses ini memastikan bahwa hasil prediksi yang ditampilkan telah dilengkapi dengan informasi evaluasi performa model.


f. `tampilkanHasilPrediksi()`

Model Prediksi (LSTM) → Admin Museum

Tahap terakhir adalah penampilan hasil prediksi kepada Admin Museum melalui fungsi `tampilkanHasilPrediksi()`. Informasi yang ditampilkan mencakup nilai prediksi jumlah pengunjung serta hasil evaluasi model. Hasil ini digunakan sebagai dasar bagi Admin Museum dalam pengambilan keputusan dan perencanaan operasional museum.

128

3) Class Diagram



Gambar 3. 5 Class Diagram

Struktur data dalam penelitian ini dimodelkan menggunakan Diagram Kelas (*Class Diagram*). Pada Gambar 3.5 *class diagram* sistem prediksi jumlah pengunjung museum digunakan untuk menggambarkan struktur dan hubungan antar bagian yang terdapat dalam aplikasi. Diagram ini terdiri dari beberapa kelas utama, yaitu Pengunjung, SistemPrediksi, Prediksi, dan Database. Kelas

125

Pengunjung berfungsi untuk mengelola data historis pengunjung museum yang nantinya digunakan sebagai data utama dalam proses prediksi. Kelas SistemPrediksi menjadi bagian inti sistem karena menangani proses preprocessing data, pelatihan model LSTM, proses prediksi jumlah pengunjung, hingga evaluasi hasil prediksi. Hasil prediksi beserta nilai evaluasi seperti MAE, RMSE, dan MAPE disimpan pada kelas Prediksi agar dapat ditampilkan kembali kepada pengguna. Selain itu, terdapat kelas *Database* yang digunakan untuk melakukan koneksi, penyimpanan, dan pengambilan data dari *database MySQL*. Hubungan antar kelas tersebut menunjukkan bahwa seluruh komponen sistem saling terhubung untuk mendukung proses prediksi jumlah pengunjung museum berbasis *web* secara terintegrasi.

4) Desain Database

Tabel 3. 2 Desain Database


Nama Kolom	Tipe Data	Deskripsi
+Id	INT(11)	Id unik pengunjung
+Tanggal	DATE	Tanggal saat kunjungan
+Nama	VARCHAR(100)	Nama pengunjung
+Alamat	TEXT	Alamat pengunjung
+Tujuan	VARCHAR(150)	Tujuan pengunjung
+Jumlah	INT(11)	Jumlah pengunjung

Struktur data dalam penelitian ini dimodelkan menggunakan Diagram Kelas (*Class Diagram*). Pada tabel 3.5 *class diagram* sistem prediksi jumlah pengunjung museum digunakan untuk menggambarkan struktur dan hubungan antar bagian yang terdapat dalam aplikasi. Diagram ini terdiri dari beberapa kelas utama, yaitu Pengunjung, SistemPrediksi, Prediksi, Admin, dan *Database*. Kelas Pengunjung berfungsi untuk mengelola data historis pengunjung museum yang

nantinya digunakan sebagai data utama dalam proses prediksi. Kelas SistemPrediksi menjadi bagian inti sistem karena menangani proses pengolahan data, pelatihan model LSTM, prediksi jumlah pengunjung, hingga evaluasi hasil prediksi. Hasil prediksi beserta nilai evaluasi seperti MAE, RMSE, dan MAPE disimpan pada kelas Prediksi agar dapat ditampilkan kembali kepada pengguna. Selain itu, terdapat kelas Admin yang berperan sebagai pengguna utama sistem untuk mengelola aplikasi, serta kelas *Database* yang digunakan untuk menyimpan dan mengambil data dari *database* MySQL. Hubungan antar kelas tersebut menunjukkan bahwa seluruh komponen sistem saling terhubung untuk mendukung proses prediksi jumlah pengunjung museum berbasis *web* secara terintegrasi.

5) Desain Antarmuka Pengguna (UI/UX Design)

a. Halaman Menu Utama



Gambar 3. 6 Halaman Menu Utama Sistem

Pada gambar 3.6 menunjukkan tampilan halaman menu utama pada Sistem Prediksi Pengunjung Museum Airlangga berbasis *web*. Halaman ini berfungsi sebagai halaman awal yang akan diakses oleh pengguna ketika membuka aplikasi. Pada bagian kiri terdapat menu navigasi yang terdiri dari Menu Utama, Data Historis, dan Prediksi. Menu-menu tersebut disediakan untuk memudahkan pengguna

dalam berpindah antarhalaman sesuai dengan kebutuhan pengelolaan data dan proses prediksi.

Pada bagian utama halaman ditampilkan informasi singkat mengenai tujuan sistem, yaitu untuk memprediksi jumlah pengunjung Museum Airlangga berdasarkan data historis pengunjung setiap bulan. Informasi ini membantu pengguna memahami fungsi utama aplikasi sebelum menggunakan fitur yang tersedia. Selain itu, terdapat tombol Mulai Prediksi yang berfungsi sebagai akses menuju proses prediksi jumlah pengunjung. Dengan adanya halaman utama ini, pengguna dapat memperoleh gambaran umum mengenai sistem sekaligus mengakses fitur-fitur yang tersedia dengan lebih mudah dan terarah.

b. Halaman Data Historis

DATA HISTORIS PENGUNJUNG					
Input Data					
Tanggal		Nama			
Alamat		Tujuan			
Jumlah Pengunjung					
Simpan		Batal			
Data Tersimpan					
No	Tanggal	Alamat	Tujuan	Jumlah Pengunjung	Aksi
1					edit hapus

71
Gambar 3. 7 Halaman Data Historis

Pada gambar 3.7 menampilkan halaman Data Historis Pengunjung pada sistem prediksi jumlah pengunjung museum berbasis web. Pada bagian sebelah kiri terdapat menu navigasi yang terdiri dari menu utama, data historis, dan prediksi yang digunakan untuk memudahkan pengguna dalam mengakses fitur pada sistem. Pada bagian utama halaman terdapat form input data yang digunakan untuk memasukkan data historis pengunjung museum seperti

tanggal kunjungan, nama pengunjung, alamat, tujuan kunjungan, dan jumlah pengunjung. Setelah data diinput, pengguna dapat menyimpan data menggunakan tombol simpan atau membatalkan input menggunakan tombol batal. Di bawah form input terdapat tabel data tersimpan yang digunakan untuk menampilkan data historis pengunjung yang telah berhasil disimpan ke dalam *database*. Pada tabel tersebut juga tersedia tombol edit dan hapus untuk mengelola data yang sudah tersimpan. Tampilan halaman ini dirancang agar proses pengelolaan data pengunjung museum dapat dilakukan dengan lebih mudah, terstruktur, dan terintegrasi dengan sistem prediksi.

c. Halaman ⁶⁷Prediksi

Gambar 3. 8 Halaman Prediksi

Pada gambar 3.8 menampilkan halaman prediksi jumlah ²⁴pengunjung pada sistem prediksi museum berbasis *web*. Pada bagian sebelah kiri terdapat menu navigasi yang terdiri dari menu utama, data historis, dan prediksi untuk memudahkan pengguna dalam berpindah halaman pada sistem. Pada bagian utama halaman terdapat fitur filter prediksi yang digunakan untuk menentukan rentang bulan data historis yang akan digunakan dalam proses prediksi. Pengguna dapat memilih bulan awal dan bulan akhir,

kemudian menekan tombol proses prediksi untuk menjalankan proses perhitungan menggunakan metode *Long Short-Term Memory* (LSTM).

Setelah proses prediksi selesai dilakukan, sistem akan menampilkan hasil evaluasi model berupa nilai MAE, RMSE, MAPE, dan akurasi model pada bagian hasil prediksi. Selain itu, sistem juga menampilkan grafik jumlah pengunjung yang digunakan untuk memvisualisasikan data historis dan hasil prediksi jumlah pengunjung museum. Tampilan halaman ini dirancang agar pengguna dapat melihat hasil prediksi dan performa model secara lebih mudah, informatif, dan interaktif.

2) Simulasi Penyelesaian Masalah

Bagian ini menjelaskan tahapan penyelesaian masalah yang diterapkan pada sistem prediksi jumlah pengunjung Museum Airlangga menggunakan metode *Long Short-Term Memory* (LSTM). Proses yang dilakukan meliputi tahap normalisasi data, pembentukan data *sequence* menggunakan teknik *sliding window*, pelatihan model LSTM, proses prediksi, denormalisasi hasil prediksi, serta evaluasi performa model menggunakan metrik MAE, RMSE, dan MAPE. Tahapan tersebut dilakukan untuk menghasilkan model yang mampu mempelajari pola kunjungan pengunjung berdasarkan data historis sehingga dapat digunakan untuk memprediksi jumlah pengunjung pada periode berikutnya. Contoh perhitungan yang ditampilkan pada bagian ini digunakan untuk menggambarkan proses pengolahan data yang dilakukan oleh sistem sebelum menghasilkan prediksi.

1) Data Input

Data yang digunakan pada penelitian ini merupakan data historis jumlah pengunjung Museum Airlangga yang tersusun berdasarkan periode bulanan (*time series*). Data diperoleh secara langsung dari pihak

Museum Airlangga dan selanjutnya disimpan ke dalam *database MySQL* pada sistem yang telah dibangun. Data historis tersebut digunakan sebagai dasar dalam proses pelatihan (*training*) dan prediksi jumlah pengunjung menggunakan metode *Long Short-Term Memory (LSTM)*.

Pada penelitian ini, data jumlah pengunjung disusun berdasarkan urutan waktu sehingga model dapat mempelajari pola perubahan jumlah pengunjung dari satu periode ke periode berikutnya. Data historis yang digunakan mencakup periode Januari 2024 hingga Maret 2026 dengan total 21 data bulanan. Seluruh data tersebut kemudian melalui tahap normalisasi, pembentukan *sliding window*, pelatihan model, hingga menghasilkan prediksi jumlah pengunjung pada periode berikutnya.

Tabel 3. 3 Data Historis

Bulan	Jumlah Pengunjung		
	2024	2025	2026
Januari	3	358	409
Februari	-	1227	232
Maret	4	56	436
April	-	235	
Mei	-	159	
Juni	-	434	
Juli	-	106	
Agustus	-	246	
September	71	337	
Oktober	317	579	
November	247	579	
Desember	392	609	

2) Normalisasi Data

Sebelum digunakan dalam proses pelatihan model, data historis terlebih dahulu dinormalisasi menggunakan metode *Min-Max Scaling*. Normalisasi bertujuan untuk mengubah rentang nilai data ke dalam skala 0 sampai 1 sehingga perbedaan nilai antar data tidak terlalu jauh dan proses pembelajaran model LSTM dapat berjalan lebih optimal.

$$x^1 = \frac{x - \min(x)}{\max(x) - \min(x)} \dots\dots\dots (3.1)$$

Keterangan :

1. x^1 = nilai hasil normalisasi
2. x = data aktual
3. $x_{\min}$ = nilai minimum data
4. $x_{\max}$ = nilai maksimum data

Pada simulasi penyelesaian masalah digunakan 6 data historis pertama sebagai contoh perhitungan. Pemilihan 6 data dilakukan karena sistem menggunakan minimal 6 bulan data historis untuk membentuk data latih dan melakukan proses prediksi yang ditunjukkan pada tabel 3.4. Seluruh data historis tetap digunakan pada proses pelatihan dan pengujian sistem yang dibahas pada Bab IV.

Tabel 3. 4 Data 6 Bulan Awal

Bulan	Jumlah Pengunjung
Januari	3
Maret	4
September	71
Oktober	317
November	247
Desember	392

Berdasarkan data tersebut diperoleh:

$$X_{min} = 3$$

$$X_{max} = 392$$

Nilai minimum diperoleh dari jumlah pengunjung terendah yaitu 3 pengunjung, sedangkan nilai maksimum diperoleh dari jumlah pengunjung tertinggi yaitu 392 pengunjung.

Perhitungan Normalisasi:

1. Januari 2024

$$X' = \frac{3 - 3}{392 - 3}$$

$$X' = \frac{0}{389}$$

$$X' = 0.000$$

2. Maret 2024

$$X' = \frac{4 - 3}{392 - 3}$$

$$X' = \frac{1}{389}$$

$$X' = 0.00257$$

$$X' \approx 0.003$$

3. September 2024

$$X' = \frac{71 - 3}{392 - 3}$$

$$X' = \frac{68}{389}$$

$$X' = 0.1748$$

$$X' \approx 0.175$$

4. Oktober 2024

$$X' = \frac{317 - 3}{392 - 3}$$

$$X' = \frac{314}{389}$$

$$X' = 0.8072$$

$$X' \approx 0.807$$

5. November 2024

$$X' = \frac{247 - 3}{392 - 3}$$

$$X' = \frac{244}{389}$$

$$X' = 0.6272$$

$$X' \approx 0.627$$

6. Desember 2024

$$X' = \frac{392 - 3}{392 - 3}$$

$$X' = \frac{389}{389}$$

$$X' = 1.000$$

3) Pembentukan *Sliding Window*

Setelah data berhasil dinormalisasi, tahap selanjutnya adalah membentuk data *sequence* menggunakan teknik *sliding window*. Teknik ini digunakan untuk mengubah data deret waktu (*time series*) menjadi pasangan data input dan target yang dapat diproses oleh model *Long Short-Term Memory* (LSTM).

Pada penelitian ini digunakan nilai *time step* sebesar 3. Nilai tersebut menunjukkan bahwa model menggunakan tiga data historis sebelumnya untuk memprediksi satu periode berikutnya. Pemilihan *time step* sebesar 3 disesuaikan dengan implementasi sistem yang dibangun

sehingga model dapat mempelajari pola perubahan jumlah pengunjung dari tiga periode sebelumnya.

Setelah normalisasi dilakukan, data dibentuk menjadi sequence sebagai berikut.

1. Sequence 1

Data input terdiri dari tiga data pertama, yaitu Januari 2024, Maret 2024, dan September 2024.

Input:[0.000, 0.003, 0.175]

Target:0.807

Tabel 3. 5 Hasil *Sequence 1*

X1	X2	X3	Target
0.000	0.003	0.175	0.807

Pada sequence pertama, model menggunakan data Januari 2024, Maret 2024, dan September 2024 untuk memprediksi jumlah pengunjung pada Oktober 2024.

2. Sequence 2

Data kemudian bergeser satu langkah ke depan.

Input:[0.003, 0.175, 0.807]

Target:0.627

Tabel 3. 6 Hasil *Sequence 2*

X1	X2	X3	Target
0.003	0.175	0.807	0.627

Pada sequence kedua, model menggunakan data Maret 2024, September 2024, dan Oktober 2024 untuk memprediksi jumlah pengunjung November 2024.

3. Sequence 3

Data kembali bergeser satu langkah ke depan.

Input:[0.175, 0.807, 0.627]

Target:1.000

Tabel 3. 7 Hasil *Sequence* 3

X1	X2	X3	Target
0.175	0.807	0.627	1.000

Pada sequence ketiga, model menggunakan data September 2024, Oktober 2024, dan November 2024 untuk memprediksi jumlah pengunjung Desember 2024.

4) Pembagian Data *Training* dan *Testing*

Setelah proses pembentukan *sliding window* selesai dilakukan, data sequence yang terbentuk selanjutnya dibagi menjadi data *training* dan data *testing*. Pembagian data ini bertujuan agar model dapat mempelajari pola dari data *training* dan kemudian diuji menggunakan data *testing* yang belum pernah digunakan selama proses pelatihan.

Pada penelitian ini digunakan pembagian data sebesar 80% untuk *training* dan 20% untuk *testing*. Persentase tersebut dipilih karena sebagian besar data digunakan untuk proses pembelajaran model, sedangkan sebagian lainnya digunakan untuk mengukur kemampuan model dalam melakukan prediksi.

Berdasarkan proses *sliding window* sebelumnya diperoleh tiga *sequence* sebagai berikut.

Tabel 3. 8 Hasil *Sequence* dari *Sliding Window*

X1	X2	X3	Target
0.000	0.003	0.175	0.807
0.003	0.175	0.807	0.627
0.175	0.807	0.627	1.000

1. Perhitungan Pembagian Data

Jumlah sequence: $n = 3$

Jumlah data *training* : $Training = 80\% \times 3 = 2,4$ (2 *sequence*)

Jumlah data *testing* : $Testing = 3 - 2 = 1$ *sequence*

Sehingga diperoleh:

Data Training = 2 Sequence

Data Testing = 1 Sequence

78

2. Data Training

Data training digunakan untuk melatih model LSTM agar dapat mempelajari pola hubungan antar data historis.

Tabel 3. 9 Data *Training*

X1	X2	X3	Target
0.000	0.003	0.175	0.807
0.003	0.175	0.807	0.627

Pada training pertama :

Input : [0.000, 0.003, 0.175]

Target : 0.807

Pada training kedua :

Input : [0.003, 0.175, 0.807]

Target : 0.637

Kedua sequence tersebut digunakan oleh model untuk mempelajari pola perubahan jumlah pengunjung.

104

3. Data Testing

Data testing digunakan untuk menguji kemampuan model setelah proses training selesai dilakukan.

Tabel 3. 10 Data *Testing*

X1	X2	X3	Target
0.175	0.807	0.627	1.000

Input : [0.175, 0.807, 0.627]

Target : 1.000

Sequence tersebut tidak digunakan selama proses pelatihan, sehingga dapat digunakan untuk mengukur kemampuan model dalam melakukan prediksi terhadap data yang belum pernah dipelajari sebelumnya.

5) Proses Prediksi

Setelah model LSTM selesai dilatih menggunakan data training, tahap berikutnya adalah melakukan prediksi menggunakan data testing. Tujuan dari tahap ini adalah untuk mengetahui kemampuan model dalam memprediksi data yang belum pernah digunakan selama proses pelatihan.

Berdasarkan pembagian data sebelumnya, diperoleh satu sequence yang digunakan sebagai data testing.

Tabel 3. 11 Data Testing

X1	X2	X3	Target
0.175	0.807	0.627	1.000

Pada data testing tersebut, model menerima tiga nilai input yaitu:

$$X_1 = 0.175$$

$$X_{12} = 0.807$$

$$X_1 = 0.627$$

Ketiga nilai tersebut diproses oleh model LSTM yang telah dilatih untuk menghasilkan nilai prediksi.

Secara umum proses prediksi dapat digambarkan sebagai berikut.

$$[0.175, 0.807, 0.627] \rightarrow \text{Model LSTM} \rightarrow \hat{Y}$$

Dengan : $\hat{Y}$ merupakan hasil prediksi dalam bentuk data normalisasi.

Model LSTM memanfaatkan pola hubungan antar data historis yang telah dipelajari selama proses pelatihan untuk memperkirakan nilai

pada periode berikutnya. Pada penelitian ini digunakan *time step* sebesar 3, sehingga model menggunakan tiga data periode sebelumnya sebagai dasar dalam menghasilkan prediksi. Hasil prediksi yang diperoleh masih berupa data normalisasi sehingga perlu dilakukan proses denormalisasi untuk mengembalikannya ke bentuk jumlah pengunjung sebenarnya.

6) Denormalisasi Data

Setelah model LSTM selesai dilatih menggunakan data training, tahap berikutnya adalah melakukan prediksi menggunakan data testing. Tujuan dari tahap ini adalah untuk mengetahui kemampuan model dalam memprediksi data yang belum pernah digunakan selama proses pelatihan.

Alur denormalisasi :

$$\hat{Y} \rightarrow \text{Denormalisasi} \rightarrow \text{Jumlah Pengunjung}$$

Keterangan:

1. $\hat{Y}$ merupakan hasil prediksi model LSTM dalam bentuk normalisasi.
2. Proses denormalisasi mengembalikan nilai tersebut ke skala data asli.
3. Hasil akhir berupa jumlah pengunjung yang dapat dipahami oleh pengguna.

Tahap denormalisasi merupakan proses akhir sebelum hasil prediksi ditampilkan oleh sistem. Melalui proses ini, nilai prediksi yang sebelumnya berada pada rentang normalisasi dikonversi kembali ke satuan jumlah pengunjung sehingga dapat digunakan sebagai informasi prediksi jumlah pengunjung museum pada periode berikutnya.

7) Ringkasan Proses Penyelesaian Masalah

Berdasarkan tahapan yang telah dijelaskan sebelumnya, proses penyelesaian masalah pada penelitian ini dimulai dengan mengumpulkan data historis jumlah pengunjung Museum Airlangga sebagai data masukan sistem. Data tersebut kemudian dinormalisasi menggunakan metode *Min-*

Max Scaling untuk menyeragamkan rentang nilai sehingga dapat diproses secara optimal oleh model. Setelah proses normalisasi, data dibentuk menjadi beberapa *sequence* menggunakan teknik *sliding window* dengan *time step* sebesar 3. Tahap ini bertujuan untuk mengubah data deret waktu (*time series*) menjadi format yang sesuai untuk dipelajari oleh metode *Long Short-Term Memory* (LSTM). *Sequence* yang telah terbentuk selanjutnya dibagi menjadi data *training* dan data *testing*, di mana data *training* digunakan untuk melatih model agar mampu mengenali pola kunjungan museum, sedangkan data *testing* digunakan untuk menguji kemampuan model dalam melakukan prediksi.

Setelah proses pelatihan selesai, model LSTM digunakan untuk memprediksi jumlah pengunjung pada periode berikutnya berdasarkan pola yang telah dipelajari dari data historis. Hasil prediksi yang diperoleh masih dalam bentuk data normalisasi sehingga perlu dilakukan proses denormalisasi untuk mengembalikannya ke bentuk jumlah pengunjung sebenarnya. Tahap terakhir adalah melakukan evaluasi model menggunakan MAE, RMSE, dan MAPE. Evaluasi ini dilakukan dengan membandingkan hasil prediksi terhadap data aktual untuk mengetahui tingkat kesalahan yang dihasilkan model. Semakin kecil nilai MAE, RMSE, dan MAPE yang diperoleh, maka semakin kecil pula selisih antara hasil prediksi dan data aktual, sehingga menunjukkan bahwa model memiliki performa yang semakin baik dalam memprediksi jumlah pengunjung museum.

HASIL DAN PEMBAHASAN


A. Hasil Penelitian

Pada penelitian ini telah berhasil membangun sistem prediksi jumlah pengunjung Museum Airlangga berbasis *web* menggunakan metode *Long Short-Term Memory* (LSTM). Sistem yang dikembangkan bertujuan untuk membantu pihak museum dalam memperkirakan jumlah pengunjung pada periode berikutnya berdasarkan data historis yang tersedia.

Sistem terdiri dari beberapa fitur utama, yaitu halaman dashboard, halaman data historis, dan halaman prediksi. Halaman dashboard berfungsi sebagai halaman utama yang memberikan informasi mengenai sistem. Halaman data historis digunakan untuk mengelola data jumlah pengunjung museum, sedangkan halaman prediksi digunakan untuk melakukan proses prediksi jumlah pengunjung menggunakan metode LSTM.

57

1. Halaman Dashboard

Gambar 4. 1 Tampilan Halaman *Dasboard*

Pada gambar 4.1 adalah tampilan Halaman dashboard yang merupakan halaman utama setelah pengguna berhasil masuk ke dalam sistem. Halaman ini berfungsi sebagai pusat navigasi yang menghubungkan pengguna dengan seluruh fitur yang tersedia. Pada halaman ini ditampilkan

informasi mengenai tujuan sistem yaitu memprediksi jumlah pengunjung Museum Airlangga berdasarkan data historis pengunjung yang tersedia.

Selain itu, pengguna dapat mengakses menu Data Historis dan Prediksi melalui panel navigasi yang terdapat pada sisi kiri halaman. Dengan adanya halaman dashboard, pengguna dapat memahami fungsi sistem sebelum melakukan proses pengolahan data maupun prediksi.

60

2. Halaman Data Historis

Gambar 4. 2 Tampilan Halaman Data Historis

49

Pada gambar 4.2 merupakan tampilan halaman data historis yang digunakan untuk mengelola data jumlah pengunjung museum yang menjadi dasar dalam proses prediksi. Pada halaman ini pengguna dapat menambahkan, mengubah, maupun menghapus data pengunjung sesuai kebutuhan.

Data historis yang tersimpan pada *database* akan digunakan oleh sistem sebagai data masukan dalam proses pelatihan model LSTM. Semakin banyak data historis yang tersedia, maka semakin banyak pola yang dapat dipelajari oleh model untuk menghasilkan prediksi yang lebih baik.

No	Tanggal	Nama	Alamat	Tujuan	Jumlah Pengunjung	Aksi
1	Minggu, 29 Maret 2026	Candy	Bali	Wisata	2	Edit Hapus
2	Minggu, 29 Maret 2026	Suroto	-	-	1	Edit Hapus
3	Minggu, 29 Maret 2026	Syifa	Wbla/Janti	Rekreasi	1	Edit Hapus
4	Minggu, 29 Maret 2026	Ratih Dkk	Kediri	Wisata	94	Edit Hapus
5	Minggu, 29 Maret 2026	Ror	Kediri	-	1	Edit Hapus
6	Minggu, 29 Maret 2026	Ozi	Pasuruan	-	1	Edit Hapus
7	Minggu, 29 Maret 2026	Vanelo	Gresik	-	1	Edit Hapus
8	Minggu, 29 Maret 2026	Alin	Mjk	-	1	Edit Hapus
9	Minggu, 29 Maret 2026	Dinda	Tuban	-	1	Edit Hapus
10	Minggu, 29 Maret 2026	Ilham	Gresik	-	1	Edit Hapus

Gambar 4. 3 Data Historis Pengunjung Museum Airlangga yang Tersimpan pada Sistem.

Pada gambar 4.3 merupakan tampilan beberapa data historis pengunjung Museum Airlangga yang telah berhasil diinput dan tersimpan pada sistem. Data yang ditampilkan meliputi tanggal kunjungan, nama pengunjung, alamat, tujuan kunjungan, dan jumlah pengunjung. Data historis tersebut digunakan sebagai dasar dalam proses prediksi jumlah pengunjung menggunakan metode *Long Short-Term Memory (LSTM)*.

Selain itu, sistem juga menyediakan fitur Edit dan Hapus untuk memudahkan pengelolaan data oleh pengguna.


25

3. Halaman Prediksi

Gambar 4. 4 Tampilan Halaman Prediksi

Halaman prediksi pada gambar 4.4 digunakan untuk melakukan proses prediksi jumlah pengunjung museum. Pada halaman ini pengguna dapat menentukan rentang data historis yang akan digunakan sebagai dasar prediksi. Hasil yang ditampilkan berupa jumlah pengunjung yang diprediksi pada periode berikutnya beserta nilai evaluasi model yang terdiri dari MAE, RMSE, MAPE, dan akurasi.

4. Hasil Prediksi Sistem



13

Gambar 4. 5 Hasil Prediksi

Berdasarkan gambar 4.5 hasil pengujian yang dilakukan menggunakan data historis Januari 2024 sampai Maret 2026 sebanyak 21 data bulanan, sistem berhasil menghasilkan prediksi jumlah pengunjung Museum Airlangga pada bulan April 2026 sebesar 390 pengunjung.

Selain menghasilkan nilai prediksi, sistem juga menampilkan jumlah pengunjung pada setiap bulan sebelumnya dan hasil evaluasi model berupa nilai *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan tingkat akurasi model.

5. Evaluasi Model

Setelah proses prediksi selesai dilakukan, sistem melakukan evaluasi untuk mengetahui tingkat performa model dalam menghasilkan prediksi. Evaluasi dilakukan menggunakan tiga metrik, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

```
===== HASIL EVALUASI MODEL LSTM =====
MAE      : 115.32
RMSE     : 135.31
MAPE     : 27.36 %
AKURASI  : 72.64 %
PREDIKSI : 389.83 pengunjung
```

Gambar 4. 6 Hasil Evaluasi Model

a. Analisis Nilai MAE

Nilai MAE sebesar 115,32 menunjukkan bahwa rata-rata selisih antara hasil prediksi yang dihasilkan model dengan data aktual adalah sekitar 115 pengunjung. Semakin kecil nilai MAE yang diperoleh, maka semakin kecil pula rata-rata kesalahan prediksi yang dihasilkan model.

b. Analisis Nilai RMSE

Nilai RMSE sebesar 135,31 menunjukkan tingkat kesalahan prediksi yang mempertimbangkan kesalahan besar secara lebih signifikan. Nilai RMSE yang sedikit lebih tinggi dibandingkan MAE mengindikasikan bahwa terdapat beberapa periode yang memiliki selisih prediksi lebih besar dibandingkan periode lainnya.

Meskipun demikian, nilai RMSE yang diperoleh masih menunjukkan bahwa model mampu mengikuti pola perubahan jumlah pengunjung yang terdapat pada data historis.

c. Analisis Nilai MAPE

Nilai MAPE sebesar 27,36% menunjukkan bahwa rata-rata persentase kesalahan prediksi model terhadap data aktual adalah sebesar 27,36%. Artinya, secara rata-rata hasil prediksi yang dihasilkan model memiliki tingkat kesalahan sekitar 27,36% dibandingkan dengan kondisi sebenarnya. Semakin kecil nilai MAPE yang diperoleh, maka semakin baik kemampuan model dalam melakukan prediksi.

d. Perhitungan Akurasi

Tingkat akurasi model digunakan untuk mengetahui seberapa baik model LSTM dalam menghasilkan prediksi jumlah pengunjung Museum Airlangga. Pada penelitian ini, akurasi dihitung berdasarkan nilai *Mean Absolute Percentage Error* (MAPE) yang diperoleh dari hasil evaluasi model.

Nilai MAPE yang dihasilkan oleh sistem adalah sebesar 27,36%. Selanjutnya, nilai akurasi dihitung menggunakan persamaan berikut:

$$Akurasi = 100\% - MAPE \dots \dots \dots (4.1)$$

Sehingga :

$$Akurasi = 100\% - 27,36\%$$

$$Akurasi = 72,64\%$$

Berdasarkan hasil perhitungan tersebut, diperoleh tingkat akurasi model sebesar 72,64%. Hasil ini menunjukkan bahwa model *Long Short-Term Memory* (LSTM) yang digunakan telah mampu memprediksi jumlah pengunjung Museum Airlangga dengan tingkat ketepatan sebesar 72,64%, sedangkan tingkat kesalahan prediksi yang dihasilkan sebesar 27,36%.

40

B. Pembahasan

Berdasarkan hasil penelitian yang telah dilakukan, sistem prediksi jumlah pengunjung Museum Airlangga berhasil dibangun dan diimplementasikan menggunakan metode *Long Short-Term Memory* (LSTM). Sistem ini dirancang untuk mengolah data historis jumlah pengunjung yang tersimpan dalam *database* menjadi informasi prediksi jumlah pengunjung pada periode berikutnya. Proses prediksi dilakukan melalui beberapa tahapan, yaitu normalisasi data menggunakan metode *Min-Max Scaling*, pembentukan *sequence* menggunakan teknik *sliding window*, pembagian data *training* dan *testing*, pelatihan model LSTM, proses prediksi, denormalisasi hasil prediksi, serta evaluasi model. Dengan memanfaatkan data historis yang tersusun dalam bentuk *time series*, model LSTM mampu mempelajari pola kunjungan pengunjung dari waktu ke waktu sehingga dapat digunakan untuk memperkirakan jumlah pengunjung pada periode mendatang.

Hasil pengujian menunjukkan bahwa model menghasilkan prediksi jumlah pengunjung sebesar 389,83 pengunjung pada periode yang diprediksi. Hasil tersebut menunjukkan bahwa metode LSTM mampu memanfaatkan pola yang terdapat pada data historis untuk menghasilkan nilai prediksi yang mendekati kondisi sebenarnya. Untuk mengetahui performa model, dilakukan evaluasi menggunakan *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Berdasarkan hasil evaluasi diperoleh nilai MAE sebesar 115,32, RMSE sebesar 135,31, dan MAPE sebesar 27,36%. Nilai MAE menunjukkan bahwa rata-rata selisih antara hasil prediksi dan data aktual berada pada kisaran 115 pengunjung, sedangkan nilai RMSE yang lebih besar dibandingkan MAE mengindikasikan adanya beberapa data yang memiliki selisih prediksi cukup tinggi. Sementara itu, nilai MAPE sebesar 27,36% menunjukkan bahwa rata-rata persentase kesalahan prediksi model terhadap data aktual berada pada angka tersebut.

80

Berdasarkan nilai MAPE yang diperoleh, tingkat akurasi model mencapai 72,64%, yang menunjukkan bahwa model LSTM memiliki

kemampuan yang cukup baik dalam memprediksi jumlah pengunjung Museum Airlangga berdasarkan data historis yang tersedia. Meskipun masih terdapat perbedaan antara hasil prediksi dan data aktual, model telah mampu mengenali pola kunjungan pengunjung dan menghasilkan prediksi yang dapat digunakan sebagai bahan pertimbangan dalam perencanaan operasional museum. Performa model yang diperoleh dipengaruhi oleh beberapa faktor, seperti jumlah data historis yang digunakan, pola kunjungan pengunjung yang fluktuatif, serta parameter model yang diterapkan selama proses pelatihan. Secara keseluruhan, hasil penelitian menunjukkan bahwa metode *Long Short-Term Memory* (LSTM) dapat diterapkan untuk memprediksi jumlah pengunjung Museum Airlangga dengan tingkat akurasi yang cukup baik, sehingga informasi yang dihasilkan dapat dimanfaatkan sebagai pendukung pengambilan keputusan dan perencanaan kegiatan di lingkungan museum.

PENUTUP

A. Kesimpulan

Menurut hasil penelitian dan pengujian yang telah dilakukan, sistem prediksi jumlah pengunjung Museum Airlangga menggunakan metode *Long Short-Term Memory* (LSTM) dapat disimpulkan sebagai berikut:

1. Dari hasil penelitian yang telah dilakukan, berhasil dirancang dan dibangun sistem prediksi jumlah pengunjung Museum Airlangga berbasis *web* yang menerapkan metode *Long Short-Term Memory* (LSTM). Sistem yang dibangun mampu mengolah data historis pengunjung dan menghasilkan prediksi jumlah pengunjung pada periode berikutnya.
2. Implementasi metode *Long Short-Term Memory* (LSTM) menghasilkan nilai MAE sebesar 115,32, RMSE sebesar 135,31, dan MAPE sebesar 27,36% dengan tingkat akurasi sebesar 72,64%. Hasil tersebut menunjukkan bahwa metode LSTM memiliki kemampuan yang cukup baik dalam memprediksi jumlah pengunjung Museum Airlangga sehingga sistem layak digunakan sebagai alat bantu dalam mendukung perencanaan kegiatan dan pengambilan keputusan berdasarkan perkiraan jumlah pengunjung pada periode mendatang.

B. Saran

Penelitian ini telah berhasil merancang sistem prediksi jumlah pengunjung Museum Airlangga menggunakan metode *Long Short-Term Memory* (LSTM). Namun, masih dapat dikembangkan untuk penelitian selanjutnya dengan meningkatkan kualitas hasil prediksi. Penelitian selanjutnya disarankan untuk menggunakan jumlah data historis yang lebih banyak agar model dapat mempelajari pola kunjungan secara lebih optimal. Selain itu, dapat dilakukan pengujian dengan variasi parameter model maupun perbandingan dengan metode prediksi lainnya untuk memperoleh performa yang lebih baik. Penambahan faktor-faktor yang memengaruhi jumlah pengunjung, seperti hari

libur, kegiatan khusus museum, dan musim wisata, juga dapat dipertimbangkan guna meningkatkan akurasi prediksi yang dihasilkan oleh sistem.

ORIGINALITY REPORT

22%

SIMILARITY INDEX

19%

INTERNET SOURCES

13%

PUBLICATIONS

10%

STUDENT PAPERS

PRIMARY SOURCES

1

Submitted to UPN Veteran Yogyakarta

Student Paper

2

repository.itpln.ac.id

Internet Source

3

etheses.uin-malang.ac.id

Internet Source

4

digilib.unila.ac.id

Internet Source

5

ejurnal.methodist.ac.id

Internet Source

6

repository.umsu.ac.id

Internet Source

7

jurnal.untag-sby.ac.id

Internet Source

8

www.stmikpontianak.ac.id

Internet Source

9

Submitted to Universitas Pamulang

Student Paper

10

docplayer.info

Internet Source

11

kc.umn.ac.id

Internet Source

12

repo.unand.ac.id

Internet Source

13

eprints.upj.ac.id

Internet Source

14

journal.uin-alauddin.ac.id

Internet Source

15

journal.unismuh.ac.id

Internet Source

-
- 16 jurnal.polibatam.ac.id
Internet Source
-
- 17 Submitted to Universitas Sanata Dharma
Student Paper
-
- 18 Submitted to IAKN Palangka Raya
Student Paper
-
- 19 repository.mediapenerbitindonesia.com
Internet Source
-
- 20 jurnal.stmiksznw.ac.id
Internet Source
-
- 21 ejurnal.seminar-id.com
Internet Source
-
- 22 repository.uin-suska.ac.id
Internet Source
-
- 23 repository.ulb.ac.id
Internet Source
-
- 24 echodock.blogspot.com
Internet Source
-
- 25 repository.usd.ac.id
Internet Source
-
- 26 Submitted to Fakultas Kedokteran
Student Paper
-
- 27 jurnal.sttmcileungsi.ac.id
Internet Source
-
- 28 pustakagalerimandiri.co.id
Internet Source
-
- 29 Submitted to Universitas Tarumanagara
Student Paper
-
- 30 Harliana Harliana, Tito Prabowo, Ady Alzhava Nuary. "Perbandingan Logistic Regressior dan Random Forest untuk Prediksi Respon Pelanggan Asuransi", Jurnal Informatika Komputer, Bisnis dan Manajemen, 2026
Publication
-
- 31 Dwinugroho Putro Utomo. "PERAMALAN PENYINARAN MATAHARI PER JAM SATU HARI I DEPAN MENGGUNAKAN MODEL LONG SHORT-TERM MEMORY (LSTM)", Jurnal Informatika dan Teknik Elektro Terapan, 2025
Publication
-

32

[Submitted to Universitas Merdeka Malang](#)Student Paper

33

[Submitted to University of Muhammadiyah Malang](#)Student Paper

34

eprints.uny.ac.idInternet Source

35

Hidayat Hidayat, Musliadi KH, Indar Kusmanto, Munawirah Kadir, Kristian Kristian. "Klasifikasi Mahasiswa Calon Penerima Beasiswa KIP Menggunakan Algoritma Naive Ba di Universitas Tomakaka Mamuju", JURNAL FASILKOM, 2025

Publication

36

[Submitted to Universitas Pendidikan Ganesha](#)Student Paper

37

[Submitted to Universitas Prima Indonesia](#)Student Paper

38

Fityan Hanif Assalmi, Wahyu Syaifullah Jauharis Saputra, Amri Muhaimin. "Analisis Pred Kata Kunci Situs Web MonsterMAC dengan Metode Long Short-Term Memory (LSTM)", Jurnal Teknologi Terpadu, 2024

Publication

39

Muhamad Rizki, Aditya Eka Danneswara, Yesa Dwi Aprilia, Muhammad Fatir Rizky Al Faj Yayan Hendrian, Shynde Limar Kinanti. "Prediksi Harga Saham Bank BRI dan Bank BCA dengan Menggunakan Model LSTM", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025

Publication

40

digilibadmin.unismuh.ac.idInternet Source

41

ejurnal.stmik-budidarma.ac.idInternet Source

42

openlibrarypublications.telkomuniversity.ac.idInternet Source

43

123dok.comInternet Source

44

[Submitted to Perpustakaan](#)Student Paper

45

[Submitted to Universitas Islam Bandung](#)Student Paper

46

ejournal.forda-mof.org

Internet Source

47 Arief Priyono, Hasby Firmansyah, Wahyu Asriyani, Rizki Prasetyo Tulodo. "Analisis Pengaruh Parameter Support Vector Machine Terhadap Akurasi Prediksi Harga Saham Jurnal Pengabdian Masyarakat dan Riset Pendidikan, 2025

Publication

48 Dyah Puspita Sari Nilam Utami, Mochamad Ikbil Arifyanto. "Prediction of Electricity Bill Payment Delays for Customers Using a Machine Learning Approach", INOVTEK Polbang Seri Informatika, 2025

Publication

49 Submitted to Konsorsium PTS Batch 5

Student Paper

50 Submitted to Rektorat (ADM)

Student Paper

51 Fenda Enjelita, Hidayatur Rohmah, Chusnul Chotimah. "Perancangan Website JAMQOS (Jamak Qoshor) Berbasis Google Sites pada Mata Pelajaran Fiqih di Kelas VII MTSN 3 Jombang", ANWARUL, 2026

Publication

52 Submitted to Universitas International Batam

Student Paper

53 Submitted to Universitas Pertahanan RI

Student Paper

54 pt.scribd.com

Internet Source

55 I Putu Arya Vidyananta Vidyananta, Kadek Teguh Dermawan Dermawan. "PERBANDINGAN ALGORITMA K-MEANS DAN K-MEDOIDS DALAM PENGELOMPOKAN PROVINSI DI INDONESIA BERDASARKAN INDIKATOR KEADAAN SEKOLAH DASAR", Jurnal Informatika dan Teknik Elektro Terapan, 2025

Publication

56 Submitted to Universitas Islam Indonesia

Student Paper

57 Submitted to Universitas Musamus Merauke

Student Paper

58 ejournal.uniks.ac.id

Internet Source

59 Muhamad Rizki Fasihullisan Damopolii, Lisna Zahrotun, Anna Hendri Soleliza Jones. "Analisis Perbandingan Metode DBSCAN dan Mean Shift Dalam Mengelompokkan Data IPM Kabupaten/Kota se-Indonesia", JURNAL FASILKOM, 2026

Publication

60 Submitted to STT PLN
Student Paper

61 Submitted to Sultan Agung Islamic University
Student Paper

62 Submitted to Universitas Khairun
Student Paper

63 blog.myskill.id
Internet Source

64 journal.universitasbumigora.ac.id
Internet Source

65 Dwi Nurmelly Handayani, Sayid Qutub. "Penerapan Random Forest Untuk Prediksi Dan Analisis Kemiskinan", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025
Publication

66 Submitted to Sriwijaya University
Student Paper

67 Submitted to Transylvania University
Student Paper

68 Submitted to UIN Sunan Gunung Djati Bandung
Student Paper

69 Submitted to Universitas Brawijaya
Student Paper

70 Submitted to Universitas Islam Riau
Student Paper

71 Submitted to Universitas Maritim Raja Ali Haji
Student Paper

72 Submitted to Universitas Sangga Buana YPKP
Student Paper

73 cdn.juris.id
Internet Source

74 informatika.unpkediri.ac.id
Internet Source

75 repository.ub.ac.id
Internet Source

76 repository.uinsu.ac.id
Internet Source

77

repository.unissula.ac.id

Internet Source

78

Felicia Amanda Cahyadewi, Ibnu Richo Kurniawan, Irsyad Umar Fakhri, Fahrizal Dent Saputra et al. "Pengaruh Penambahan Arsitektur Model dalam Klasifikasi Citra Bencana Alam Menggunakan Ensemble Learning", JURNAL FASILKOM, 2025

Publication

79

Submitted to Telkom University

Student Paper

80

Submitted to Universitas Pendidikan Indonesia

Student Paper

81

Submitted to Universitas Sumatera Utara

Student Paper

82

etd.repository.ugm.ac.id

Internet Source

83

openjournal.unpam.ac.id

Internet Source

84

publikasi.hawari.id

Internet Source

85

Eko Fuji Pangestu -, Bambang Irawan -. "KLASIFIKASI PENYAKIT TANAMAN PADI MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR MOBILNETV2", Jurnal Informatika dan Teknik Elektro Terapan, 2026

Publication

86

Muhammad Miftakhudin, Aang Alim Murtopo, Zaenul Arif. "Integrasi Artificial Neural Network dan Algoritma Genetika untuk Prediksi Bencana Banjir Pesisir Kota Tegal", RIG Journal of Artificial Intelligence and Digital Business, 2025

Publication

87

e-jurnal.pnl.ac.id

Internet Source

88

Submitted to itera

Student Paper

89

mail.bajangjournal.com

Internet Source

90

mts-mji.blogspot.com

Internet Source

91

text-id.123dok.com

Internet Source

92

www.scribd.com

Internet Source

93

www.slideshare.net

Internet Source

94

Nurlindasari Tamsir, Thabrani R, St. Amina H. Umar, Vivi Rosida. "Algoritma Naïve Baye untuk Prediksi Kualitas Sperma", DoubleClick: Journal of Computer and Information Technology, 2023

Publication

95

Shelly Kurnia Ulisyah, Briansyah Setio Wiyono. "Comparison of the Effectiveness of NocoDB and Nocobase Performance in the Development of Electronic-Based Governm System Applications", INOVTEK Polbeng - Seri Informatika, 2025

Publication

96

ejournal.unesa.ac.id

Internet Source

97

jurnal.istts.ac.id

Internet Source

98

jurusan.tik.pnj.ac.id

Internet Source

99

pdfs.semanticscholar.org

Internet Source

100

repository.its.ac.id

Internet Source

101

repository.maranatha.edu

Internet Source

102

www.coursehero.com

Internet Source

103

www.netralnews.com

Internet Source

104

Fahreza Adams Lazuardy, Ahmad Homaidi, Ahmad Lutfi. "Perbandingan Metode Data Mining PERBANDINGAN METODE KLASIFIKASI PENGUJIAN KENDARAAN BERMOTOR DENGAN ALGORITMA C4.5 DAN NAÏVE BAYES", E-Link: Jurnal Teknik Elektro dan Informatika, 2024

Publication

105

Isfa Auliyani, Anisah Anisah. "Digitalisasi Absensi Dan Jurnal Harian Guru Berbasis Web Menggunakan Metode RAD", Jurnal Minfo Polgan, 2026

Publication

-
- 106 MUHAMMAD MATHORI ABDUL JALIL, Umi Chotijah, Putri Aisyiyah Rakhma Devi. "SISTEM PREDIKSI PENJUALAN DENGAN METODE SINGLE EXPONENTIAL SMOOTHING (STUDI KASUS CV. BU IPUNG LAMONGAN)", Indexia, 2021
Publication
-
- 107 Muhammad Atharsyah, Moh. Ali Romli. "IMPLEMENTASI MODEL LSTM, GRU, BILSTM, D. BIGRU DALAM PREDIKSI HARGA NIKEL", Jurnal Informatika dan Rekayasa Elektronik, 20
Publication
-
- 108 Nabila Putri Anjali, Dean Tirkaamiana. "Penerapan Metode Holt-Winters untuk Forecast Kebutuhan Gas Alam pada Perusahaan Listrik", Jurnal Teknik Industri Terintegrasi, 2021
Publication
-
- 109 Octhafianus Zalukhu, Mhd. Dicky Syahputra Lubis, Puji Chairu Sabila. "Perancangan Sistem Informasi Stok Barang Masuk dan Barang Keluar dengan Menggunakan Metode Fifo Berbasis Web di Percetakan CV. Sumaindo", RIGGS: Journal of Artificial Intelligence and Digital Business, 2026
Publication
-
- 110 Saefudin, Diki Susandi, Fairuza Nafis. "SISTEM PERAMALAN PENJUALAN PAVING BLOCK MENGGUNAKAN METODE SINGLE MOVING AVERAGE", JSil (Jurnal Sistem Informasi), 20
Publication
-
- 111 Submitted to Universitas 17 Agustus 1945 Semarang
Student Paper
-
- 112 Wetina Hulu, Rani Rosalinda, Ronita Olive Angelie, Sardo Sipayung. "Analisis Nilai dan Kehadiran Mahasiswa untuk Pengembangan Pengetahuan Akademik Menggunakan Clustering K-Means dan Statistik", Jurnal Minfo Polgan, 2026
Publication
-
- 113 Widyawati Widyawati, Dadang Amiruddin. "**TRANSFORMASI DATA TRANSAKSI KE DER WAKTU DAN EVALUASI MODEL PERAMALAN PERMINTAAN PADA MARKETPLACE PLAZA BANTEN**", Journal of Innovation And Future Technology, 2026
Publication
-
- 114 Zulnani Tinggi, Sakum. "PENGEMBANGAN EARLY WARNING SYSTEM UNTUK DELISTING SAHAM SYARIAH MENGGUNAKAN SUPPORT VECTOR MACHINE (SVMs)", Jurnal Ekonom Syariah Pelita Bangsa, 2020
Publication
-
- 115 ahmadmuhsinupn.blogspot.com
Internet Source
-
- 116 braintext.ai
Internet Source
-
- 117 dspace.uii.ac.id
Internet Source
-

118

ejournal.ukrida.ac.idInternet Source

119

eprints.pktj.ac.idInternet Source

120

eprints.uns.ac.idInternet Source

121

heri.staff.unisbank.ac.idInternet Source

122

journalcenter.orgInternet Source

123

jurnal.unimed.ac.idInternet Source

124

library.likmi.ac.idInternet Source

125

lppm-stmikhandayani.ac.idInternet Source

126

mojokerto.citybase.co.idInternet Source

127

qdoc.tipsInternet Source

128

repository.amikom.ac.idInternet Source

129

repository.ar-raniry.ac.idInternet Source

130

repository.uinjkt.ac.idInternet Source

131

repository.unej.ac.idInternet Source

132

repository.unimus.ac.idInternet Source

133

www.researchgate.netInternet Source

134

www.websitehostingrating.comInternet Source

135 Agustin Agustin, Junadhi Junadhi, Fransiskus Zoromi, Parlindungan Kudadiri. "Analisis Sentimen Kesehatan Mental Pemuda di Media Sosial Menggunakan Deep Learning", *DEVICE : JOURNAL OF INFORMATION SYSTEM, COMPUTER SCIENCE AND INFORMATION TECHNOLOGY*, 2025

Publication

136 doku.pub
Internet Source

137 Agastya Andresangsya, Muhammad Fauzan Aditiya Mufid, Alief Cahyo Utomo, Yudhi Darmawan. "Implementasi Regresi Linier untuk Prediksi Harga Saham Tesla", *JSITIK: Jur Sistem Informasi dan Teknologi Informasi Komputer*, 2025

Publication

138 Akhmad Faeda Insani, Ahmad Mushawir, Zainuddin, Aditya Adiaksa, Sparisoma Viridi. "Optimization of Variable Combinations for Household Electricity Consumption Predict Using a Multivariate Time Series Machine Learning Approach", *INOVTEK Polbeng - Seri Informatika*, 2024

Publication

139 Fia Hamasyatus Syahadah, Ridho Taufiq Subagio, Putri Rizqiyah. "PENERAPAN XGBOOS DALAM PREDIKSI PENDAFTARAN SISWA BARU BIMBINGAN BELAJAR QSC DI KOTA CIREBON", *Jurnal Informatika dan Teknik Elektro Terapan*, 2025

Publication

140 Hasriadi Hasriadi, Iqbal Iqbal. "Prediksi Harga Bitcoin Multivariat OHLC Berbasis Hybrid LSTM–GRU dan Sentimen Berita", *Jurnal Minfo Polgan*, 2026

Publication

141 Muchamad Aries Firmansyah, Aang Alim Murtopo, Nurul Fadilah. "Penerapan Metode Fuzzy Tsukamoto untuk Prediksi Jumlah Produksi PT Wings Padaharja", *RIGGS: Journal Artificial Intelligence and Digital Business*, 2025

Publication

142 Tanty Nazala Asyla, Apriade Voutama. "Perancangan UI/UX Absensi dan Penggajian Pelatih Berbasis Website Menggunakan Metode Design Thinking", *RIGGS: Journal of Artificial Intelligence and Digital Business*, 2026

Publication

143 Widya Dwi Putri Yosyahlinda, April Lia Hananto, Elfina Novalia, Shofa Shofia Hilabi. "IMPLEMENTASI ALGORITMA MULTIPLE LINEAR REGRESSION UNTUK PREDIKSI PENGELUARAN HARIAN PADA PT HARUM MAJU MAPAN", *Technologia : Jurnal Ilmiah*, 2025

Publication