

# Analisis Temporal Long Short-Term Memory untuk Prediksi Pendapatan Penjualan dalam Mendukung Ketahanan Finansial UMKM

## *Long Short-Term Memory Temporal Analysis for Sales Revenue Forecasting to Support the Financial Resilience of MSMEs*

Rizqa Zahrotun Nafiah<sup>a,1,\*</sup>, Bambang Agus Herlambang<sup>a,2</sup>, Noora Qotrun Nada<sup>a,3</sup>

<sup>a</sup>Program Studi Informatika, Universitas PGRI Semarang, Kota Semarang, Indonesia  
<sup>1</sup>[rizqazahrotun@gmail.com](mailto:rizqazahrotun@gmail.com); <sup>2</sup>[bambangherlambang@upgris.ac.id](mailto:bambangherlambang@upgris.ac.id); <sup>3</sup>[noora@upgris.ac.id](mailto:noora@upgris.ac.id);  
\*corresponding author

| Informasi Artikel                                                                                                                                                                                                                  | ABSTRAK                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                          |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p>Diserahkan : 30 April 2026<br/>Diterima : 18 Mei 2026<br/>Direvisi : 7 Agustus 2026<br/>Diterbitkan : 26 Agustus 2026</p> <p><b>Kata Kunci:</b><br/>UMKM<br/>Prediksi Pendapatan Penjualan<br/>LSTM<br/>Sistem Berbasis Web</p> | <p>Usaha Mikro, Kecil, dan Menengah (UMKM) memainkan peran penting dalam pembangunan ekonomi, namun banyak UMKM menghadapi ketidakpastian dalam perencanaan pendapatan penjualan akibat fluktuasi permintaan dan terbatasnya pemanfaatan alat peramalan berbasis data. Penelitian ini mengusulkan sistem prediksi pendapatan penjualan berbasis web untuk UMKM menggunakan metode <i>Long Short-Term Memory</i> (LSTM) guna memodelkan data penjualan harian yang memiliki karakteristik nonlinier dan temporal. Dataset yang digunakan terdiri dari data pendapatan penjualan harian selama lima tahun dari UMKM Rayanza Fashion, dengan total 1.827 data. Arsitektur <i>stacked</i> LSTM dengan tiga lapisan LSTM digunakan dan dievaluasi menggunakan <i>Mean Absolute Error</i> (MAE), <i>Root Mean Squared Error</i> (RMSE), dan <i>Mean Absolute Percentage Error</i> (MAPE). Hasil eksperimen menunjukkan bahwa model mampu memprediksi pendapatan penjualan harian secara efektif, dengan nilai MAE sebesar 13.904 rupiah, RMSE sebesar 16.410 rupiah, dan MAPE sebesar 4,38% pada data pengujian. Hasil ini menunjukkan kemampuan generalisasi yang baik serta pembelajaran yang efektif terhadap tren penjualan dan pola musiman. Model yang telah dilatih kemudian diintegrasikan ke dalam sistem berbasis web menggunakan React.js sebagai <i>frontend</i>, Express.js sebagai <i>backend</i>, dan FastAPI untuk penyajian model. Penelitian ini memberikan kontribusi berupa sistem prediksi pendapatan penjualan <i>end-to-end</i> yang dapat diimplementasikan untuk mendukung pengambilan keputusan berbasis data pada UMKM.</p> |
| <p><b>Keywords:</b><br/>MSMEs<br/>Sales Revenue Prediction<br/>LSTM<br/>Web-Based System</p>                                                                                                                                       | <p><b>ABSTRACT</b></p> <p><i>Micro, Small, and Medium Enterprises (MSMEs) play a crucial role in economic development, yet many MSMEs face uncertainty in sales revenue planning due to fluctuating demand and limited use of data-driven forecasting tools. This study proposes a web-based sales revenue prediction system for MSMEs using the Long Short-Term Memory (LSTM) method to model daily sales data with nonlinear and temporal characteristics. The dataset consists of five years of daily sales revenue data from Rayanza Fashion MSME, comprising 1,827 records. A stacked LSTM architecture with three LSTM layers is employed and evaluated using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE). Experimental results show that the model predicts daily sales revenue effectively, achieving an MAE of 13,904 rupiah, an RMSE of 16,410 rupiah, and a MAPE of 4.38% on the testing data. These results indicate good generalization capability and effective learning of sales trends and seasonal patterns. The trained model is integrated into a web-based system using React.js as the frontend, Express.js as the backend, and FastAPI for model serving. This research contributes an end-to-end deployable sales revenue prediction system that supports data-driven decision-making for MSMEs.</i></p>                                                                                                                                                                                                                                                         |

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



## I. Pendahuluan

Usaha Mikro, Kecil, dan Menengah (UMKM) memiliki peran strategis dalam mendukung perekonomian, khususnya dalam penciptaan lapangan kerja dan peningkatan kesejahteraan masyarakat [1]. Namun demikian,

banyak pelaku UMKM masih menghadapi berbagai tantangan dalam pengelolaan usaha, salah satunya adalah ketidakpastian pendapatan penjualan [2]. Ketidakstabilan pendapatan ini sering kali menyebabkan perencanaan usaha menjadi kurang optimal, karena pengambilan keputusan belum sepenuhnya didasarkan pada data historis [3]. Akibatnya, pelaku usaha mengalami kesulitan dalam menentukan strategi produksi, pengelolaan persediaan, serta pengambilan keputusan keuangan yang akurat [4].

Permasalahan tersebut semakin diperparah oleh praktik pengelolaan data penjualan yang masih bersifat manual atau belum terintegrasi dengan baik [5]. Data penjualan historis yang dimiliki UMKM belum dimanfaatkan secara optimal untuk menghasilkan informasi prediktif yang akurat dan mudah diakses [6]. Kondisi ini menyulitkan UMKM dalam memperkirakan pendapatan penjualan di masa depan, sehingga meningkatkan risiko ketidaksesuaian antara permintaan pasar dan kapasitas usaha [7]. Tanpa adanya sistem prediksi yang andal, pelaku UMKM cenderung mengandalkan intuisi dalam pengambilan keputusan, yang berpotensi menimbulkan inefisiensi operasional serta kerugian finansial.

Sejumlah penelitian sebelumnya telah mengeksplorasi prediksi penjualan menggunakan berbagai pendekatan berbasis data [8]. Namun, sebagian besar penelitian tersebut masih berfokus pada analisis offline dan belum terintegrasi dalam sistem berbasis web yang mudah digunakan oleh pelaku UMKM [9]. Selain itu, penerapan model deep learning, khususnya Long Short-Term Memory (LSTM) yang dirancang untuk memodelkan data deret waktu penjualan dalam sistem yang terintegrasi, masih relatif terbatas [10]. Hal ini menunjukkan adanya kesenjangan antara kebutuhan UMKM akan sistem prediksi pendapatan penjualan yang praktis, akurat, dan mudah diakses, dengan ketersediaan solusi teknologi yang siap digunakan dalam operasional sehari-hari.

Perkembangan teknologi informasi membuka peluang untuk menjembatani kesenjangan tersebut melalui pemanfaatan sistem berbasis web dan metode machine learning [8]. Long Short-Term Memory (LSTM), sebagai salah satu jenis Recurrent Neural Network (RNN), mampu menangkap pola jangka pendek maupun jangka panjang dalam data deret waktu, sehingga sangat sesuai untuk memprediksi pendapatan penjualan yang bersifat dinamis dan fluktuatif [11], [12]. Penelitian yang dilakukan oleh Sirisha et al. mengembangkan sistem prediksi keuntungan dengan membandingkan model Seasonal ARIMA (SARIMA), ARIMA, dan LSTM. Hasil penelitian menunjukkan bahwa model LSTM memiliki kinerja yang lebih unggul dibandingkan SARIMA dan ARIMA dalam prediksi keuntungan, dengan tingkat akurasi mencapai 97,01% [13]. Temuan ini menegaskan potensi besar LSTM dalam memodelkan pola penjualan yang kompleks dan nonlinier.

Dalam tiga tahun terakhir, berbagai penelitian juga menunjukkan bahwa metode LSTM memiliki performa yang baik dalam prediksi data deret waktu penjualan karena mampu menangkap pola nonlinier dan musiman secara lebih efektif dibandingkan metode statistik konvensional [8], [12], [13]. Meskipun demikian, sebagian besar penelitian tersebut masih berfokus pada pengujian performa model secara eksperimental dan belum mengimplementasikan model prediksi ke dalam sistem yang dapat digunakan langsung oleh pelaku UMKM dalam operasional sehari-hari [12], [14]. Selain itu, sebagian penelitian hanya menitikberatkan pada aspek akurasi model tanpa memperhatikan integrasi antarmuka pengguna dan kemudahan akses sistem berbasis web.

Penelitian ini memperkuat temuan penelitian terdahulu bahwa LSTM efektif digunakan untuk prediksi pendapatan penjualan berbasis data deret waktu [15]. Namun demikian, penelitian ini juga menyempurnakan penelitian sebelumnya melalui pengembangan sistem prediksi berbasis web secara end-to-end yang mengintegrasikan model LSTM dengan frontend React.js, backend Express.js, dan layanan model menggunakan FastAPI. Dengan demikian, penelitian ini tidak hanya berfokus pada evaluasi performa model, tetapi juga pada implementasi sistem prediktif yang dapat digunakan secara langsung sebagai alat pendukung pengambilan keputusan bagi UMKM.


Berdasarkan latar belakang tersebut, penelitian ini mengusulkan pengembangan sistem prediksi pendapatan penjualan UMKM berbasis web menggunakan metode Long Short-Term Memory (LSTM). Sistem yang diusulkan bertujuan untuk menghasilkan prediksi pendapatan yang akurat serta menyajikan hasilnya melalui antarmuka yang mudah digunakan oleh pelaku UMKM. Diharapkan, sistem ini dapat meningkatkan kualitas perencanaan usaha dan pengambilan keputusan, serta memberikan kontribusi akademis dalam penerapan LSTM pada sistem prediksi pendapatan penjualan UMKM.

## II. Metode

Penelitian ini menggunakan pendekatan sistematis untuk mengembangkan sistem prediksi pendapatan penjualan UMKM berbasis web dengan metode Long Short-Term Memory (LSTM). Metodologi penelitian meliputi analisis permasalahan penjualan UMKM yang bersifat deret waktu, perancangan model dan arsitektur sistem, serta implementasi dan evaluasi solusi yang diusulkan. Tahapan penelitian disajikan dalam bentuk alur pemrosesan data dan diagram arsitektur yang menggambarkan proses mulai dari pengolahan data penjualan mentah, pembentukan data deret waktu, pelatihan dan evaluasi model LSTM, hingga integrasi model terlatih ke dalam sistem berbasis web untuk mendukung pengambilan keputusan berbasis data.

### A. Alur Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan sistematis yang bertujuan untuk mengembangkan sistem prediksi pendapatan penjualan UMKM berbasis web menggunakan metode *Long Short-Term Memory* (LSTM). Proses penelitian mencakup pengumpulan data penjualan historis, persiapan dan prapemrosesan data, pembentukan data deret waktu, pelatihan model LSTM dan evaluasi kinerja, serta implementasi model dalam sistem berbasis web [16]. Alur penelitian secara lengkap ditunjukkan pada Gambar 1.



Gambar 1. Alur penelitian

Secara rinci, alur penelitian dimulai dari tahap pengumpulan data, yaitu mengumpulkan data penjualan harian historis dari UMKM. Data yang diperoleh kemudian masuk ke tahap persiapan data, yang meliputi pengurutan secara kronologis serta pemeriksaan awal untuk mengidentifikasi ketidakkonsistenan dan data yang hilang. Selanjutnya dilakukan rekayasa fitur dengan membentuk data deret waktu serta fitur berbasis lag untuk menangkap pola temporal dalam penjualan. Dataset kemudian dibagi menjadi data pelatihan dan pengujian dengan proporsi masing-masing 85% dan 15% [17].

Pada tahap berikutnya dilakukan prapemrosesan data yang meliputi pembersihan data, normalisasi fitur, serta penanganan nilai hilang untuk meningkatkan kualitas input model. Model LSTM dilatih menggunakan data pelatihan dengan penerapan learning rate yang sesuai serta teknik early stopping untuk mencegah overfitting [18]. Kinerja model dievaluasi menggunakan metrik MAE, RMSE, dan MAPE pada data pengujian [19]. Model terbaik kemudian disimpan dan diimplementasikan dalam sistem berbasis web untuk menghasilkan prediksi pendapatan penjualan secara otomatis.

### B. Deskripsi dan Persiapan Dataset

Dataset yang digunakan berasal dari UMKM Rayanza Fashion, yang bergerak pada bidang fesyen. Dataset terdiri atas data pendapatan penjualan harian selama lima tahun (1 Januari 2020 hingga 31 Desember 2024) dengan total 1.827 data. Setiap data terdiri atas atribut tanggal transaksi dan total pendapatan penjualan harian. Dataset ini digunakan sebagai dasar pembentukan data deret waktu untuk proses pelatihan dan evaluasi model LSTM. Rentang waktu yang panjang memungkinkan model untuk mempelajari pola musiman, tren jangka panjang, serta fluktuasi penjualan secara komprehensif [20].

Dalam implementasi sistem berbasis web, pengguna diwajibkan mengunggah data penjualan harian dengan durasi minimal satu tahun. Hal ini bertujuan agar data memiliki informasi temporal yang cukup untuk mendukung pembentukan urutan data yang stabil serta performa prediksi yang konsisten [21].

### C. Prapemrosesan Data

Tahap prapemrosesan dimulai dengan mengurutkan dataset berdasarkan waktu serta menghapus nilai yang tidak valid [22]. Selanjutnya dilakukan rekayasa fitur berbasis waktu untuk memperkaya informasi input model. Fitur tambahan yang digunakan meliputi hari dalam minggu, indikator akhir pekan, nilai penjualan hari sebelumnya (lag-1), nilai penjualan tujuh hari sebelumnya (lag-7), serta rata-rata bergerak 7 hari dan 30 hari [23].

Seluruh fitur numerik dinormalisasi menggunakan metode Min-Max Scaling dalam rentang 0 hingga 1. Normalisasi ini bertujuan menjaga stabilitas proses pelatihan LSTM dan mencegah dominasi fitur dengan skala besar [24].

### D. Pembagian Dataset dan Strategi Validasi

Dataset yang telah diproses dibagi menggunakan pendekatan berbasis waktu, dengan 85% data digunakan untuk pelatihan dan 15% untuk pengujian [25]. Pendekatan ini menjaga urutan temporal data serta mencegah kebocoran informasi.


Data deret waktu dibentuk menggunakan teknik sliding window dengan panjang jendela 90 hari [26]. Setiap urutan data digunakan untuk memprediksi nilai penjualan pada hari berikutnya. Dataset pengujian digunakan untuk mengevaluasi performa model setelah proses pelatihan selesai [27].

#### E. Arsitektur Model

Model prediksi pendapatan penjualan dalam penelitian ini menggunakan arsitektur stacked LSTM yang dirancang untuk memodelkan data deret waktu penjualan UMKM secara efektif. LSTM dipilih karena kemampuannya dalam menangkap dependensi jangka pendek dan jangka panjang dalam data sekuensial [28].

Arsitektur model terdiri dari tiga lapisan LSTM berturut-turut dengan jumlah unit masing-masing 128, 64, dan 32 [29]. Lapisan pertama menerima input berupa urutan data dengan panjang tertentu dan dimensi fitur sesuai data pelatihan. Parameter *return\_sequences* diatur bernilai *true* pada dua lapisan pertama agar seluruh urutan keluaran diteruskan ke lapisan berikutnya. Lapisan ketiga berfungsi sebagai representasi akhir yang menghasilkan vektor fitur temporal.

Setiap lapisan LSTM diikuti oleh lapisan Dropout dengan nilai 0,3 pada dua lapisan pertama dan 0,2 pada lapisan ketiga untuk mengurangi overfitting [30]. Setelah itu, digunakan lapisan Dense dengan 32 neuron dan aktivasi ReLU untuk memodelkan hubungan non-linier [31]. Lapisan output terdiri dari satu neuron tanpa fungsi aktivasi untuk menghasilkan prediksi nilai penjualan harian. Arsitektur model LSTM yang digunakan di penelitian ini digambarkan seperti pada Gambar 2.



Gambar 2. Diagram arsitektur model

Model dikompilasi menggunakan optimizer Adam dengan learning rate 0,001 dan fungsi loss Mean Squared Error (MSE) [32], [33]. Dalam proses pelatihan, model stacked LSTM menggunakan batch size 16, epoch 100, dan verbose 1. Batch size 16 dipilih untuk menjaga keseimbangan antara efisiensi komputasi dan stabilitas pembelajaran, sedangkan penggunaan 100 epoch bertujuan agar model dapat mempelajari pola temporal data penjualan secara optimal. Parameter verbose 1 digunakan untuk menampilkan progres pelatihan pada setiap epoch.

Secara matematis, mekanisme internal jaringan LSTM terdiri dari tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*, yang berfungsi untuk mengatur aliran informasi dalam sel memori [34]. *Forget gate* menentukan informasi mana dari *cell state* sebelumnya yang perlu dipertahankan, *input gate* mengontrol penambahan informasi baru, sedangkan *output gate* menentukan informasi yang diteruskan ke *hidden state* [35]. *Forget Gate* dirumuskan sebagaimana ditunjukkan pada Persamaan (1).

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

*Input gate* dan *candidate cell state* didefinisikan masing-masing pada Persamaan (2) dan (3).

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_f[h_{t-1}, x_t] + b_c) \quad (3)$$

Pembaruan *cell state* dihitung menggunakan Persamaan (4).

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (4)$$

Selanjutnya, *output gate* dan *hidden state* dinyatakan pada Persamaan (5) dan (6).

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

$$h_t = o_t \odot \tanh(C_t) \quad (6)$$

Pada persamaan-persamaan tersebut,  $x_t$  merepresentasikan input pada waktu ke- $t$ ,  $h_t$  menyatakan *hidden state*, dan  $C_t$  merupakan *cell state*. Fungsi  $\sigma$  adalah fungsi aktivasi sigmoid, sedangkan simbol  $\odot$  menunjukkan perkalian elemen per elemen (*element-wise multiplication*). Mekanisme ini memungkinkan model untuk mempertahankan informasi penting dari data historis sekaligus beradaptasi terhadap perubahan pola penjualan secara dinamis.

#### F. Evaluasi Model

Evaluasi model dilakukan untuk mengukur kemampuan arsitektur LSTM dalam memprediksi pendapatan penjualan harian UMKM secara akurat [36]. Model yang telah dilatih diuji menggunakan dataset pengujian yang tidak terlibat dalam proses pelatihan, sehingga hasil evaluasi mencerminkan kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya [37].

Dalam penelitian ini, kinerja model dievaluasi menggunakan beberapa metrik regresi yang umum digunakan dalam peramalan deret waktu, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) [38]. Penggunaan beberapa metrik evaluasi bertujuan untuk memberikan penilaian yang komprehensif terhadap performa model, baik dari sisi kesalahan kuadrat, kesalahan absolut, maupun kesalahan relatif terhadap nilai aktual [39].

*Mean Squared Error* (MSE) digunakan sebagai fungsi *loss* selama proses pelatihan model [40]. Metrik ini mengukur rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual, sehingga memberikan penalti yang lebih besar terhadap kesalahan prediksi yang besar [41]. Secara matematis, MSE dirumuskan sebagai berikut.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

*Root Mean Squared Error* (RMSE) merupakan akar kuadrat dari MSE dan digunakan untuk menginterpretasikan kesalahan prediksi dalam satuan yang sama dengan data pendapatan penjualan [42]. RMSE sensitif terhadap nilai ekstrem dan memberikan gambaran umum mengenai seberapa jauh hasil prediksi menyimpang dari nilai aktual [43]. Rumus RMSE dinyatakan sebagai berikut.

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

*Mean Absolute Percentage Error* (MAPE) digunakan untuk mengukur kesalahan prediksi dalam bentuk persentase, sehingga lebih mudah diinterpretasikan dari perspektif bisnis [44]. Metrik ini sangat relevan bagi UMKM karena menunjukkan besarnya kesalahan prediksi relatif terhadap nilai pendapatan penjualan aktual. Rumus MAPE dinyatakan sebagai berikut.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (9)$$

Selain evaluasi numerik, dilakukan juga evaluasi visual dengan membandingkan nilai aktual dan nilai prediksi pada dataset pengujian. Analisis visual ini bertujuan untuk menilai kemampuan model dalam menangkap tren penjualan dan pola musiman, serta mengidentifikasi kemungkinan terjadinya *underfitting* atau *overfitting* yang mungkin tidak sepenuhnya tercermin dari metrik evaluasi numerik [45].


#### G. Pengembangan Sistem Web

Sistem prediksi pendapatan penjualan dikembangkan menggunakan arsitektur tiga lapisan (*three-tier architecture*) yang terdiri dari lapisan antarmuka pengguna (*user interface*), lapisan backend aplikasi, dan lapisan layanan model prediksi. Arsitektur ini memisahkan komponen presentasi, logika aplikasi, dan pemrosesan model, sehingga menghasilkan desain sistem yang terstruktur serta meningkatkan kemudahan pemeliharaan (*maintainability*). Lapisan antarmuka pengguna dikembangkan menggunakan React.js. Pada lapisan ini, pengguna dapat mengunggah data pendapatan penjualan harian dengan durasi minimal satu tahun, melihat ringkasan data historis, serta mengakses hasil prediksi yang disajikan dalam bentuk grafik dan numerik. React.js bertanggung jawab dalam menangani interaksi pengguna serta mengirimkan permintaan ke backend melalui protokol HTTP.



Lapisan backend aplikasi dikembangkan menggunakan Express.js untuk memvalidasi data yang diunggah, menangani request, serta memfasilitasi komunikasi antara frontend dan layanan prediksi. Backend juga mengembalikan respons ke frontend dalam format JSON. Sementara itu, layanan prediksi diimplementasikan menggunakan FastAPI yang bertugas memuat model LSTM, melakukan prapemrosesan data, membangun urutan data dengan pendekatan *sliding window*, serta menjalankan inferensi untuk menghasilkan prediksi pendapatan penjualan sebelum diteruskan kembali ke frontend melalui backend Express.js.

Alur kerja keseluruhan sistem berbasis web ditunjukkan pada Gambar 3.



Gambar 3. Alur sistem

Dalam alur tersebut, data penjualan yang diunggah oleh pengguna diproses secara berurutan mulai dari antarmuka pengguna hingga layanan model prediksi. Hasil prediksi kemudian disajikan kepada pengguna dalam bentuk estimasi nilai pendapatan penjualan, sehingga sistem dapat berfungsi sebagai alat pendukung keputusan berbasis data bagi pelaku UMKM.

### III. Hasil dan Pembahasan

#### A. Karakteristik Dataset dan Analisis Eksploratif

Dataset yang digunakan dalam penelitian ini diperoleh dari data historis pendapatan penjualan harian UMKM Rayanzza Fashion selama periode lima tahun. Dataset terdiri dari dua atribut utama, yaitu tanggal transaksi dan nilai pendapatan penjualan harian, dengan total 1.827 data. Rentang waktu pengamatan yang cukup panjang ini memberikan informasi temporal yang memadai bagi model untuk mempelajari pola musiman tahunan, tren jangka panjang, serta fluktuasi penjualan harian yang dinamis. Gambaran umum dataset yang digunakan dalam penelitian ini ditunjukkan pada Gambar 4.

|      | Tanggal    | Omzet  |
|------|------------|--------|
| 0    | 2020-01-01 | 282741 |
| 1    | 2020-01-02 | 279857 |
| 2    | 2020-01-03 | 284078 |
| 3    | 2020-01-04 | 288745 |
| 4    | 2020-01-05 | 280250 |
| ...  | ...        | ...    |
| 1822 | 2024-12-27 | 337969 |
| 1823 | 2024-12-28 | 336135 |
| 1824 | 2024-12-29 | 340519 |
| 1825 | 2024-12-30 | 342176 |
| 1826 | 2024-12-31 | 334806 |


[1827 rows x 2 columns]

Gambar 4. Contoh dataset pendapatan harian UMKM

Visualisasi data historis pada Gambar 4 menunjukkan adanya fluktuasi pendapatan penjualan yang signifikan dari waktu ke waktu, disertai pola musiman yang berulang sepanjang periode pengamatan. Karakteristik ini mengindikasikan adanya dependensi temporal yang kuat dalam data deret waktu penjualan serta hubungan yang cenderung nonlinier. Oleh karena itu, pendekatan berbasis Long Short-Term Memory (LSTM) dinilai sesuai untuk memodelkan dinamika penjualan dan menangkap pola jangka pendek maupun jangka panjang secara lebih efektif.

#### B. Kinerja Pelatihan Model

Kinerja pelatihan model LSTM dianalisis dengan membandingkan nilai *training loss* dan *validation loss* selama proses pelatihan, sebagaimana ditunjukkan pada Gambar 5. Grafik tersebut menunjukkan penurunan *training loss* yang signifikan pada epoch-epoch awal, yang mengindikasikan bahwa model mampu mempelajari pola dasar dari data penjualan secara efektif.




Gambar 5. Contoh dataset pendapatan harian UMKM


Seiring bertambahnya epoch, training loss menurun secara stabil dan cenderung konvergen, sementara validation loss hanya mengalami fluktuasi kecil dan tetap berada pada rentang rendah. Kondisi ini menunjukkan bahwa model tidak mengalami overfitting yang signifikan karena selisih antara training loss dan validation loss tetap terjaga selama pelatihan. Stabilitas kedua kurva pada epoch akhir juga mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.

### C. Analisis Kinerja Model


Evaluasi kinerja model dilakukan untuk menilai kemampuan model dalam memprediksi nilai penjualan secara akurat dan konsisten berdasarkan data historis. Evaluasi dilakukan melalui analisis proses pelatihan, perbandingan hasil prediksi terhadap data aktual pada data pelatihan (*training*) dan data pengujian (*testing*), serta perbandingan dengan metode *baseline* Linear Regression dan ARIMA menggunakan metrik MAE, RMSE, dan MAPE.

Gambar 6. Perbandingan penjualan actual dan prediksi pada data *training*

Pada data pelatihan, sebagaimana ditunjukkan pada Gambar 6, kurva prediksi menunjukkan kesesuaian yang baik dengan nilai penjualan actual. Model mampu mengikuti tren utama serta fluktuasi musiman yang terdapat pada data, meskipun masih terdapat deviasi pada beberapa titik dengan perubahan penjualan yang cukup tinggi. Hal ini menunjukkan bahwa model berhasil mempelajari karakteristik utama data penjualan selama proses pelatihan.

Gambar 7. Perbandingan penjualan actual dan prediksi pada data *testing*

Pada data pengujian, sebagaimana ditunjukkan pada Gambar 7, model LSTM mampu mengikuti pola penjualan secara umum, namun menghasilkan kurva prediksi yang lebih halus dibandingkan data aktual. Akurasi cenderung menurun pada periode yang mengalami lonjakan atau penurunan penjualan secara drastis karena model hanya memanfaatkan pola historis dan belum mempertimbangkan variabel eksternal, seperti tanggal merah, hari libur nasional, periode promosi, atau kampanye pemasaran. Akibatnya, perubahan permintaan yang terjadi secara tiba-tiba tidak dapat dipelajari selama proses pelatihan sehingga tingkat kesalahan prediksi meningkat pada titik-titik ekstrem.




Gambar 8. Perbandingan MAPE, RMSE, dan MAE pada Model LSTM, Linear Regression, dan ARIMA

Untuk mengevaluasi efektivitas metode, model LSTM dibandingkan dengan Linear Regression dan ARIMA menggunakan dataset, pembagian data, dan *feature engineering* yang sama. Hasil pengujian menunjukkan bahwa model LSTM memperoleh nilai MAE sebesar Rp13.904, RMSE sebesar Rp16.410, dan MAPE sebesar 4,38%. Sementara itu, Linear Regression memperoleh MAE sebesar Rp14.291, RMSE sebesar Rp16.740, dan MAPE sebesar 4,50%, sedangkan ARIMA memperoleh MAE sebesar Rp14.469, RMSE sebesar Rp16.995, dan MAPE sebesar 4,61%.

Nilai MAE, RMSE, dan MAPE yang lebih rendah menunjukkan bahwa model LSTM memiliki performa prediksi terbaik dibandingkan kedua metode pembandingan. Hal ini mengindikasikan bahwa LSTM lebih efektif dalam mempelajari ketergantungan temporal dan pola nonlinier pada data penjualan, sedangkan Linear Regression terbatas pada hubungan linier antarvariabel dan ARIMA lebih berfokus pada pola historis runtun waktu sehingga kurang mampu menangkap pola yang lebih kompleks.

Secara keseluruhan, hasil pengujian menunjukkan bahwa model LSTM mampu memodelkan pola penjualan harian UMKM Rayanzza Fashion dengan baik serta memberikan performa yang lebih baik dibandingkan Linear Regression dan ARIMA. Meskipun demikian, akurasi model masih menurun pada periode dengan perubahan penjualan yang ekstrem. Hal ini menunjukkan bahwa pola historis saja belum sepenuhnya mampu merepresentasikan faktor-faktor eksternal yang memengaruhi penjualan. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penambahan variabel seperti hari libur nasional, periode promosi, kampanye pemasaran, maupun faktor musiman untuk meningkatkan akurasi prediksi.


#### D. Implementasi Sistem



Gambar 9. Halaman utama implementasi sistem web

Hasil implementasi pada Gambar 9 menunjukkan bahwa model prediksi pendapatan penjualan berbasis LSTM telah berhasil diintegrasikan ke dalam sistem web menggunakan arsitektur tiga lapisan (*three-tier architecture*) yang terdiri dari antarmuka pengguna, backend aplikasi, dan layanan model prediksi. Sistem dirancang dengan antarmuka user-friendly yang menyediakan halaman beranda, prediksi, informasi sistem, serta akses langsung ke fitur prediksi untuk membantu UMKM dalam perencanaan penjualan berbasis kecerdasan buatan.





Gambar 10. Halaman prediksi sistem web

Fitur utama sistem tersedia pada halaman prediksi penjualan, sebagaimana ditunjukkan pada Gambar 10, di mana pengguna dapat mengunggah data penjualan historis dalam format Excel (.xlsx). Setelah data diunggah, sistem secara otomatis melakukan prapemrosesan dan menjalankan model prediksi. Hasil prediksi ditampilkan dalam bentuk ringkasan MAPE, estimasi pertumbuhan, total proyeksi penjualan, serta prediksi penjualan tujuh hari ke depan secara interaktif. Implementasi ini menunjukkan bahwa sistem dapat berfungsi sebagai alat pendukung keputusan berbasis data bagi pelaku UMKM.

#### E. Implikasi untuk UMKM

Hasil implementasi dan pengujian menunjukkan bahwa sistem prediksi pendapatan penjualan berbasis web yang dikembangkan memiliki implikasi praktis yang signifikan bagi pelaku UMKM. Sistem ini menyediakan alat prediksi yang berbasis data dan mudah digunakan, sehingga memungkinkan pelaku usaha melakukan perencanaan produksi, pengelolaan persediaan, serta pengambilan keputusan keuangan secara lebih sistematis dan terukur. Dengan adanya sistem ini, keputusan bisnis tidak lagi hanya bergantung pada intuisi, melainkan didukung oleh hasil prediksi yang objektif.

Sistem diuji menggunakan dataset historis pendapatan penjualan UMKM Rayanza Fashion yang terdiri atas 1.827 data harian selama lima tahun. Hasil pengujian menunjukkan bahwa sistem mampu menghasilkan nilai Mean Absolute Percentage Error (MAPE) sebesar 4,38%, yang menunjukkan tingkat kesalahan prediksi yang rendah. Temuan ini menunjukkan bahwa sistem mampu memodelkan pola penjualan harian secara baik dan berpotensi mendukung proses perencanaan usaha berbasis data pada UMKM.

#### IV. Kesimpulan dan saran

Penelitian ini berhasil mengembangkan sistem prediksi pendapatan penjualan UMKM Rayanza Fashion berbasis web menggunakan metode Long Short-Term Memory (LSTM). Berdasarkan hasil pengujian, model LSTM memperoleh nilai MAE sebesar Rp13.904, RMSE sebesar Rp16.410, dan MAPE sebesar 4,38%. Hasil tersebut menunjukkan bahwa LSTM memberikan performa prediksi yang lebih baik dibandingkan metode pembandingan Linear Regression (MAE Rp14.291, RMSE Rp16.740, MAPE 4,50%) dan ARIMA (MAE Rp14.469, RMSE Rp16.995, MAPE 4,61%), sehingga lebih efektif dalam memodelkan pola temporal penjualan harian. Meskipun demikian, performa model masih menurun pada periode dengan perubahan penjualan yang ekstrem karena penelitian ini hanya memanfaatkan fitur historis dan temporal tanpa mempertimbangkan variabel eksternal, seperti tanggal merah, hari libur nasional, periode promosi, dan kampanye pemasaran. Oleh karena itu, penelitian selanjutnya dapat menambahkan variabel eksternal serta menguji model pada lebih banyak UMKM agar kemampuan generalisasi dan akurasi prediksi dapat ditingkatkan.

#### Daftar Pustaka

- [1] S. Vinatra, "Peran Usaha Mikro, Kecil, dan Menengah (UMKM) dalam Kesejahteraan Perekonomian Negara dan Masyarakat," *Jurnal Akuntan Publik*, vol. 1, no. 3, hlm. 01–08, Jul 2023, doi: 10.59581/jap-widyakarya.v1i3.832.
- [2] N. Aktaviana, A. Awalia, N. Holilah, V. Silviani, dan A. Muslim, "Profil Bisnis Usaha Mikro, Kecil Dan Menengah (Ukm) Selama Pandemi Covid-19 Di Desa Cikakak Kecamatan Cikakak Kabupaten Sukabumi," *Jurnal Abdi Nusa*, vol. 3, no. 2, hlm. 87–91, Jun 2023, doi: 10.52005/abdinusa.v3i2.61.
- [3] N. I. Okeke, O. A. Bakare, dan G. O. Achumie, "Forecasting financial stability in SMEs: A comprehensive analysis of strategic budgeting and revenue management," *Open Access Research Journal of Multidisciplinary Studies*, vol. 8, no. 1, hlm. 139–149, Sep 2024, doi: 10.53022/oarjms.2024.8.1.0055.

- [4] G. Wang, M. Huang, S. C. Perera, S. Jiang, dan S.-C. Fang, "Integrating Supply, Production, and Demand Uncertainties in Manufacturing Inventory Systems," *IEEE Trans. Eng. Manag.*, vol. 72, no. 9, hlm. 3749–3764, Sep 2025, doi: 10.1109/TEM.2025.3599638.
- [5] A. A. Yuniarto dan I. W. Siregar, "From Manual to Digital: Modernizing the Sales Recording System for Growth at MSME Rumah Abon," *Journal of Scientific Insights*, vol. 2, no. 5, hlm. 510–525, Sep 2025, doi: 10.69930/jsi.v2i5.537.
- [6] A. R. Oktavian dan F. Rumaissa, "Penerapan Business Intelligence Terhadap Data Penjualan UMKM (Foodendez) Menggunakan Metode Algoritma Apriori Dalam Menentukan Segmentasi Pasar," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 6, no. 3, hlm. 1740, Jul 2022, doi: 10.30865/mib.v6i3.4338.
- [7] N. Hikmah, A. Fauzi, dan F. U. Nayyiroh, "Measuring the forecast accuracy in retail MSMEs: A comparative analysis between AI and traditional methods in the era of digital selling," *Journal of Management and Informatics*, vol. 4, no. 1, hlm. 687–705, Apr 2025, doi: 10.51903/jmi.v4i1.166.
- [8] G. Tamami dan M. Arifin, "Penggunaan LSTM dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens," *JURNAL FASILKOM*, vol. 14, no. 2, hlm. 301–308, Agu 2024, doi: 10.37859/jf.v14i2.7372.
- [9] P. Labastida, M. Simbulan, C. J. Estrella, W. Flores, dan C. Criselle, "Web-based ordering system for Start-UP business with forecasting," *World Journal of Advanced Research and Reviews*, vol. 22, no. 3, hlm. 357–368, Jun 2024, doi: 10.30574/wjarr.2024.22.3.1721.
- [10] T. de Castro Moraes, X. Yuan, dan E. P. Chew, "Hybrid convolutional long short-term memory models for sales forecasting in retail," *J. Forecast.*, vol. 43, no. 5, hlm. 1278–1293, Agu 2024, doi: 10.1002/for.3073.
- [11] M. M. Aqil dan F. Fauzi, "Enhancing E-commerce Supply Chains with Time-Series Forecasting Using Long Short-Term Memory (LSTM) Networks," *PatternIQ Mining*, vol. 99, hlm. 650–655, Feb 2025, doi: 10.70023/sahd/250204.
- [12] R. Feng, Z. Wu, dan J. Gong, "Application of Long Short-Term Memory for prediction of monthly tobacco sales volume," *Highlights in Business, Economics and Management*, vol. 53, hlm. 192–200, Mar 2025, doi: 10.54097/d7f26736.
- [13] U. M. Sirisha, M. C. Belavagi, dan G. Attigeri, "Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time Series Forecasting: A Comparison," *IEEE Access*, vol. 10, hlm. 124715–124727, 2022, doi: 10.1109/ACCESS.2022.3224938.
- [14] M. Khan, A. Ahmad, F. Sobieczky, M. Pichler, B. A. Moser, dan I. Bukovsky, "A Systematic Mapping Study of Predictive Maintenance in SMEs," *IEEE Access*, vol. 10, hlm. 88738–88749, 2022, doi: 10.1109/ACCESS.2022.3200694.
- [15] A. Vishwanath, M. Basheeruddin, dan S. D., "Forecasting Sales Data Using Time Series Models and LSTM Model," dalam *2024 Second International Conference on Advances in Information Technology (ICAIT)*, IEEE, Jul 2024, hlm. 1–6. doi: 10.1109/ICAIT61638.2024.10690408.
- [16] I. Ritharson, P. J. Anitha, dan S. I. Alex Pandian, "A Web-based Real-time Sales Data Analysis using LSTM Model for Better Insight," dalam *2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS)*, IEEE, Mar 2023, hlm. 1060–1064. doi: 10.1109/ICACCS57279.2023.10112837.
- [17] Q.-Q. He, C. Wu, dan Y.-W. Si, "LSTM with particle Swarm optimization for sales forecasting," *Electron. Commer. Res. Appl.*, vol. 51, hlm. 101118, Jan 2022, doi: 10.1016/j.eierap.2022.101118.
- [18] H. Santosa dan Kusriani, "Book Sales Forecasting with Bidirectional LSTM: Outlier Handling and Overfitting Reduction Using Clipping and Early Stopping," *Dinasti International Journal of Education Management And Social Science*, vol. 6, no. 6, hlm. 5328–5334, Sep 2025, doi: 10.38035/dijemss.v6i6.5449.
- [19] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," *Geosci. Model Dev.*, vol. 15, no. 14, hlm. 5481–5487, Jul 2022, doi: 10.5194/gmd-15-5481-2022.
- [20] Md. I. A. Efati dkk., "Deep-learning model using hybrid adaptive trend estimated series for modelling and forecasting sales," *Ann. Oper. Res.*, vol. 339, no. 1–2, hlm. 297–328, Agu 2024, doi: 10.1007/s10479-022-04838-6.

- [21] H. Ahaggach, L. Abrouk, dan E. Lebon, "Systematic Mapping Study of Sales Forecasting: Methods, Trends, and Future Directions," *Forecasting*, vol. 6, no. 3, hlm. 502–532, Jul 2024, doi: 10.3390/forecast6030028.
- [22] O. S. P. Tamba dan Md. M. Hasan, "Hybrid LSTM-MLP Framework for Enhanced Sales Forecasting," *IJACI : International Journal of Advanced Computing and Informatics*, vol. 2, no. 2, hlm. 75–82, Okt 2025, doi: 10.71129/ijaci.v2i2.pp75-82.
- [23] Y. Ensafi, S. H. Amin, G. Zhang, dan B. Shah, "Time-series forecasting of seasonal items sales using machine learning – A comparative analysis," *International Journal of Information Management Data Insights*, vol. 2, no. 1, hlm. 100058, Apr 2022, doi: 10.1016/j.jjime.2022.100058.
- [24] S. Sinsomboonthong, "Performance Comparison of New Adjusted Min-Max with Decimal Scaling and Statistical Column Normalization Methods for Artificial Neural Network Classification," *Int. J. Math. Math. Sci.*, vol. 2022, hlm. 1–9, Apr 2022, doi: 10.1155/2022/3584406.
- [25] K. Moussa, K. M. Elsayed, M. S. Darweesh, A. Elbaz, dan A. Soltan, "Predicting the availability of power line communication nodes using semi-supervised learning algorithms," *Sci. Rep.*, vol. 15, no. 1, hlm. 17670, Mei 2025, doi: 10.1038/s41598-025-01064-5.
- [26] Z. Zhan dan S.-K. Kim, "Versatile time-window sliding machine learning techniques for stock market forecasting," *Artif. Intell. Rev.*, vol. 57, no. 8, hlm. 209, Jul 2024, doi: 10.1007/s10462-024-10851-x.
- [27] R. S. Ahmed, M. Hasnain, M. H. Mahmood, dan M. A. Mehmood, "Comparison of Deep Learning Algorithms for Retail Sales Forecasting," *ICCK Transactions on Intelligent Systematics*, vol. 1, no. 3, hlm. 112–126, Okt 2024, doi: 10.62762/TIS.2024.300700.
- [28] F. Messaoudi, M. Loukili, dan M. El Ghazi, "Demand Prediction Using Sequential Deep Learning Model," dalam *2023 International Conference on Information Technology (ICIT)*, IEEE, Agu 2023, hlm. 577–582. doi: 10.1109/ICIT58056.2023.10225930.
- [29] I. Salehin dan D.-K. Kang, "A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain," *Electronics (Basel)*, vol. 12, no. 14, hlm. 3106, Jul 2023, doi: 10.3390/electronics12143106.
- [30] S. Ullah, A. Javed, M. Aljaseem, dan A. K. J. Saudagar, "Eff-ReLU-Net: a deep learning framework for multiclass wound classification," *BMC Med. Imaging*, vol. 25, no. 1, hlm. 257, Jul 2025, doi: 10.1186/s12880-025-01785-z.
- [31] Y.-L. Peng dan W.-P. Lee, "Practical guidelines for resolving the loss divergence caused by the root-mean-squared propagation optimizer," *Appl. Soft Comput.*, vol. 153, hlm. 111335, Mar 2024, doi: 10.1016/j.asoc.2024.111335.
- [32] M. Reyad, A. M. Sarhan, dan M. Arafa, "A modified Adam algorithm for deep neural network optimization," *Neural Comput. Appl.*, vol. 35, no. 23, hlm. 17095–17112, Agu 2023, doi: 10.1007/s00521-023-08568-z.
- [33] J. Terven, D.-M. Cordova-Esparza, J.-A. Romero-González, A. Ramírez-Pedraza, dan E. A. Chávez-Urbíola, "A comprehensive survey of loss functions and metrics in deep learning," *Artif. Intell. Rev.*, vol. 58, no. 7, hlm. 195, Apr 2025, doi: 10.1007/s10462-025-11198-7.
- [34] H. Yadav dan A. Thakkar, "NOA-LSTM: An efficient LSTM cell architecture for time series forecasting," *Expert Syst. Appl.*, vol. 238, hlm. 122333, Mar 2024, doi: 10.1016/j.eswa.2023.122333.
- [35] Y. Liu, "Deep Learning for Enterprise Sales Prediction: Haressing CNN-LSTM-Attention Model," dalam *2024 IEEE 3rd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA)*, IEEE, Feb 2024, hlm. 746–750. doi: 10.1109/EEBDA60612.2024.10485889.
- [36] S. Ghimire, T. Celik, M. Gerdes, dan C. W. Omlin, "Deep learning for blood glucose level prediction: How well do models generalize across different data sets?," *PLoS One*, vol. 19, no. 9, hlm. e0310801, Sep 2024, doi: 10.1371/journal.pone.0310801.
- [37] H. Chen, X. Li, Y. Wu, L. Zuo, M. Lu, dan Y. Zhou, "Compressive Strength Prediction of High-Strength Concrete Using Long Short-Term Memory and Machine Learning Algorithms," *Buildings*, vol. 12, no. 3, hlm. 302, Mar 2022, doi: 10.3390/buildings12030302.
- [38] A. Mystakidis, P. Koukaras, N. Tsalikidis, D. Ioannidis, dan C. Tjortjis, "Energy Forecasting: A Comprehensive Review of Techniques and Technologies," *Energies (Basel)*, vol. 17, no. 7, hlm. 1662, Mar 2024, doi: 10.3390/en17071662.

- [39] Y. Tian, D. Su, S. Lauria, dan X. Liu, "Recent advances on loss functions in deep learning for computer vision," *Neurocomputing*, vol. 497, hlm. 129–158, Agu 2022, doi: 10.1016/j.neucom.2022.04.127.
- [40] A. Mystakidis, P. Koukaras, N. Tsalikidis, D. Ioannidis, dan C. Tjortjis, "Energy Forecasting: A Comprehensive Review of Techniques and Technologies," *Energies (Basel)*, vol. 17, no. 7, hlm. 1662, Mar 2024, doi: 10.3390/en17071662.
- [41] Y. Sun dan T. Li, "A transformer-based framework for enterprise sales forecasting," *PeerJ Comput. Sci.*, vol. 10, hlm. e2503, Nov 2024, doi: 10.7717/peerj-cs.2503.
- [42] D. S. K. Karunasingha, "Root mean square error or mean absolute error? Use their ratio as well," *Inf. Sci. (N. Y.)*, vol. 585, hlm. 609–629, Mar 2022, doi: 10.1016/j.ins.2021.11.036.
- [43] K. Warneke, S. D. Siegel, J. Afonso, dan S. Wallot, "What the mean absolute percentage error (MAPE) should adopt from Bland–Altman analyses," *German Journal of Exercise and Sport Research*, Des 2025, doi: 10.1007/s12662-025-01084-3.
- [44] G. M. C. de Araújo, A. L. da Silva, H. S. Gonçalves, dan A. M. M. Correia, "Management of Micro and Small Enterprises (MPEs): Sales Forecasting in the Retail Sector," *Revista de Gestão Social e Ambiental*, vol. 18, no. 9, hlm. e08295, Agu 2024, doi: 10.24857/rgsa.v18n9-170.
- [45] S. Lima, A. M. Gonçalves, dan M. Costa, "Predictive accuracy of time series models applied to economic data: the European countries retail trade," *J. Appl. Stat.*, vol. 51, no. 9, hlm. 1818–1841, Jul 2024, doi: 10.1080/02664763.2023.2238249.