

Penerapan Model Long Short-Term Memory (LSTM) dalam Prediksi Pendapatan dan Stok Berbasis Deret Waktu pada UMKM

Muhammad Fajar Luthfiana ^{1*}, Fidi Supriadi ², David Setiadi ³

^{1,2,3} Jurusan Informatika, Universitas Sebelas April, Indonesia

¹ mfajarluthfiana@gmail.com, ² fidi@unsap.ac.id, ³ david@unsap.ac.id

Diajukan: 19 November 2025 | Direvisi: 25 Desember 2025 | Diterima: 26 Desember 2025 | Diterbitkan: 30 Januari 2026

Abstrak

Fluktuasi pendapatan yang terjadi pada toko grosir telur umumnya dipengaruhi oleh perubahan harga pasar, tingkat permintaan konsumen, serta faktor musiman yang berdampak pada kesulitan pemilik usaha dalam melakukan perencanaan keuangan secara akurat. Dengan menggunakan data deret waktu, penelitian ini berupaya memprediksi pendapatan Toko Grosir Telur Rizki menggunakan metode Long Short-Term Memory (LSTM). LSTM dipilih karena kemampuannya dalam mengenali pola jangka panjang pada data nonlinier dan menghasilkan prediksi yang lebih andal dibandingkan metode konvensional seperti regresi linear. Data penelitian mencakup pendapatan kotor dan biaya operasional yang digunakan untuk menghitung laba bersih sebagai dasar analisis. Proses penelitian meliputi pengumpulan data, pra-pemrosesan menggunakan MinMaxScaler, pembangunan dan pelatihan model LSTM, serta evaluasi menggunakan metrik Mean Absolute Error (MAE) dan Mean Absolute Percentage Error (MAPE). Temuan penelitian menunjukkan bahwa model LSTM menghasilkan tingkat kesalahan prediksi dengan nilai MAPE sebesar 11.82% dan 5.00%. Nilai MAPE sebesar 5.00% termasuk dalam kategori sangat baik (<10%), sedangkan nilai MAPE sebesar 11.82% berada pada kategori baik (10–20%). Dengan demikian, model LSTM dinilai cukup efektif dalam memprediksi pendapatan dan berpotensi mendukung pengambilan keputusan bisnis secara lebih efisien.

Kata Kunci: Deep Learning, LSTM, MAPE, Prediksi Stok, Prediksi Pendapatan, Time Series.

Abstract

Revenue fluctuations in egg wholesale businesses are generally influenced by changes in market prices, consumer demand levels, and seasonal factors, which often make it difficult for business owners to conduct accurate financial planning. Using time series data, this study aims to predict the revenue of Rizki Egg Wholesale Store by applying the Long Short-Term Memory (LSTM) method. LSTM is selected due to its capability to capture long-term patterns in nonlinear data and to produce more reliable predictions compared to conventional methods such as linear regression. The research data include gross revenue and operational costs, which are used to calculate net profit as the basis for analysis. The research process involves data collection, preprocessing using MinMaxScaler, development and training of the LSTM model, and evaluation using the Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE) metrics. The findings indicate that the LSTM model produces prediction errors with MAPE values of 11.82% and 5.00%. A MAPE value of 5.00% is classified as very good (<10%), while a MAPE value of 11.82% falls into the good category (10–20%). Therefore, the LSTM model is considered sufficiently effective in predicting revenue and has the potential to support more efficient business decision-making.

Keywords: Deep Learning, LSTM, MAPE, Stock Prediction, Revenue Prediction, Time Series.



This work is an open access article and licensed under a Creative Commons Attribution-NonCommercial ShareAlike 4.0 International (CC BY-NC-SA 4.0). Copyright (C) Author's.

1. PENDAHULUAN

Prediksi yang akurat merupakan elemen krusial dalam perencanaan bisnis, memungkinkan organisasi untuk menyelaraskan sumber daya dengan permintaan yang diantisipasi. Khususnya di sektor ritel, fluktuasi harga pasar dan pola permintaan konsumen yang tidak stabil seringkali menimbulkan tantangan signifikan, menyebabkan ketidakpastian dalam pengelolaan inventori dan estimasi pendapatan. Mengingat pentingnya data historis, metode tradisional seperti regresi linear sempat digunakan, namun efektivitasnya terbatas dan rentan terhadap *error* dalam memodelkan hubungan non-linear dan kompleks di pasar modern [1]. Oleh karena itu, pelaku usaha membutuhkan sistem prediksi yang lebih canggih untuk mencapai efisiensi operasional dan mendukung keputusan strategis [2].

Dalam beberapa tahun terakhir, fokus telah beralih ke ranah *Deep Learning* sebagai solusi untuk masalah prediksi deret waktu (*time series*). Jaringan Saraf Tiruan Berulang (*Recurrent Neural Network/RNN*) dan khususnya *Long Short-Term Memory* (LSTM), telah muncul sebagai algoritma yang unggul, memanfaatkan mekanisme *gate* untuk mengatasi masalah *vanishing gradient* dan mengingat pola jangka panjang dalam data sekuensial. Studi komparatif menunjukkan bahwa model LSTM secara signifikan mengungguli model tradisional seperti ARIMA, dengan penurunan tingkat kesalahan prediksi rata-rata sebesar 84% hingga 87%. Penurunan ini disebabkan oleh kemampuan LSTM dalam memodelkan hubungan nonlinier dan ketergantungan jangka panjang pada data deret waktu, yang tidak dapat ditangani secara optimal oleh ARIMA. Selain itu, LSTM lebih adaptif terhadap fluktuasi dan noise pada data penjualan, sehingga menghasilkan prediksi yang lebih stabil dan akurat.[3]. LSTM terbukti lebih andal untuk prediksi harga aset [4]. Lebih lanjut, LSTM juga menunjukkan potensi unggul untuk prediksi jangka pendek (per jam) dalam konteks ritel, melengkapi kekuatan ARIMA dalam pemodelan jangka panjang [5].

Keandalan model LSTM telah teruji dalam berbagai domain yang melibatkan fluktuasi data tinggi, khususnya pada pasar finansial dan komoditas. Dalam memprediksi aset yang sangat volatil, LSTM menunjukkan performa tinggi pada pasar aset digital seperti Ethereum [6] dan Bitcoin [4], serta saham spesifik seperti PT Bank Central Asia (BCA) [7] dan Indofood Sukses Makmur (INDF) [8]. Analisis ini juga diperluas ke prediksi harga komoditas strategis, di mana perbandingan antara LSTM dan *Gated Recurrent Unit* (GRU) menunjukkan akurasi yang menjanjikan untuk memprediksi fluktuasi harga minyak [9]. Bukti dari berbagai studi kasus ini, termasuk dalam prediksi harga pokok nasional [10], memperkuat argumen bahwa LSTM adalah alat yang tepat untuk memprediksi sales dan revenue dalam konteks bisnis yang dinamis.

Didorong oleh keberhasilan ini, penelitian terus berlanjut ke arsitektur yang lebih maju. Para peneliti telah mengembangkan model hibrida, seperti penggabungan LSTM dengan XGBoost untuk sistem prediksi penjualan *real-time* [2]. Selain itu, perbaikan arsitektur murni LSTM juga dilakukan, misalnya dengan menambahkan mekanisme *attention* (LSTM-attention-LSTM) untuk meningkatkan akurasi dengan memberikan bobot yang berbeda pada langkah waktu yang relevan [11]. Validasi kinerja model-model ini secara rutin mengandalkan metrik yang transparan dan dapat diinterpretasikan dalam konteks bisnis, seperti *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE) [12].


Meskipun LSTM telah banyak digunakan dalam prediksi harga komoditas dan saham, penerapannya pada konteks UMKM grosir telur masih relatif jarang dibahas. Padahal, komoditas telur merupakan bahan pangan pokok dengan tingkat permintaan yang tinggi serta fluktuasi harga yang signifikan, sehingga pelaku UMKM grosir berada pada posisi yang rentan terhadap risiko kesalahan estimasi pendapatan dan stok. Ketiadaan penelitian yang secara khusus mengkaji prediksi pendapatan dan stok pada UMKM grosir telur menciptakan kesenjangan pengetahuan

yang penting untuk diisi, terutama mengingat peran strategis UMKM dalam menjaga stabilitas rantai pasok pangan lokal.

Secara teoretis, LSTM dipilih karena kemampuannya dalam memodelkan ketergantungan temporal jangka panjang pada data deret waktu, bahkan ketika jumlah data relatif terbatas. Mekanisme *gating* pada LSTM memungkinkan model untuk menyaring informasi yang relevan dan mengurangi pengaruh noise, sehingga lebih stabil dibandingkan metode statistik konvensional pada dataset kecil dengan fluktuasi tinggi. Selain itu, LSTM tidak memerlukan asumsi stasioneritas yang ketat seperti pada model ARIMA, sehingga lebih fleksibel dalam menangkap pola nonlinier yang umum ditemukan pada data penjualan UMKM. Oleh karena itu, penelitian ini memiliki urgensi yang tinggi untuk mengembangkan model prediksi berbasis Long Short-Term Memory (LSTM) pada Toko Grosir Telur Rizki menggunakan data historis deret waktu. Akurasi prediksi yang dihasilkan diharapkan dapat meningkatkan efisiensi pengelolaan stok serta mendukung pengambilan keputusan bisnis yang lebih strategis dan berkelanjutan.

2. METODE PENELITIAN/ALGORITMA

Alur keseluruhan proses penelitian ditunjukkan pada Gambar 1, yang menggambarkan tahapan mulai dari pengumpulan data hingga evaluasi model.



Gambar 1. Alur Penelitian

2.1. Dataset

Tabel 1. Dataset yang telah melalui tahap pra-pemrosesan

Tahun	Bulan	Pendapatan (Rp)	Stok Terjual (Kg)
2023	Januari	15.368.975	8.473
2023	Februari	13.947.950	7.578
2023	Maret	13.982.570	8.013
2023	April	22.914.375	9.915
2023	Mei	17.649.875	9.301
2023	Juni	14.305.325	7.968
2023	Juli	14.497.400	8.562
2023	Agustus	17.899.850	8.325
2023	September	20.666.200	7.821
2023	Oktober	15.875.800	7.898
2023	November	13.205.500	7.083
2023	Desember	16.359.000	8.267

Tahun	Bulan	Pendapatan (Rp)	Stok Terjual (Kg)
2024	Januari	14.876.550	7.529
2024	Februari	14.560.700	6.981
2024	Maret	16.128.800	6.313
2024	April	20.453.150	7.643
2024	Mei	16.038.600	7.358
2024	Juni	16.097.625	6.760
2024	Juli	13.813.000	7.283
2024	Agustus	17.013.000	7.501
2024	September	18.300.900	7.286
2024	Oktober	15.877.000	7.243
2024	November	16.516.100	7.198
2024	Desember	18.439.500	7.158

Dataset yang digunakan dalam penelitian ini merupakan data primer yang diperoleh langsung dari UMKM Toko Grosir Telur Rizki, dengan periode pengamatan selama dua tahun, yaitu dari Januari 2023 hingga Desember 2024. Data yang tersedia terdiri atas dua variabel utama, yakni pendapatan bulanan dan jumlah stok terjual. Jumlah data yang relatif terbatas ini mencerminkan kondisi nyata proses pencatatan pada UMKM, di mana pencatatan transaksi umumnya masih dilakukan secara manual dan hanya tersedia dalam bentuk rekapitulasi bulanan. Meskipun demikian, dataset bulanan selama dua tahun dianggap cukup representatif untuk menggambarkan pola pendapatan serta pergerakan stok dalam konteks usaha ritel tradisional, sekaligus memberikan dasar yang memadai untuk proses analisis dan pemodelan prediksi.

2.2. Pengumpulan Data

Tahapan awal penelitian ini adalah pengumpulan data historis dari Toko Grosir Telur Rizki yang meliputi dua variabel utama, yaitu pendapatan kotor dan stok barang. Data dikumpulkan dalam bentuk deret waktu (time series) dengan periode pengamatan bulanan. Variabel pendapatan kotor digunakan untuk merepresentasikan performa penjualan toko, sedangkan variabel stok digunakan untuk menggambarkan tingkat persediaan barang yang tersedia setiap bulan. Sumber data diperoleh secara langsung dari pencatatan keuangan dan inventori toko selama periode pengamatan tertentu. Data kemudian disimpan dalam format digital (CSV atau Excel) agar dapat diolah menggunakan google colab untuk proses analisis dan pemodelan prediksi[13][14].

2.3. Preprocessing

Sebelum digunakan untuk pelatihan model, data harus melalui tahap pra-pemrosesan agar memiliki kualitas yang baik dan sesuai dengan kebutuhan algoritma *Long Short-Term Memory*. Tahapan preprocessing meliputi:

- Pembersihan data (data cleaning): Menghapus nilai kosong, duplikat, atau data yang tidak relevan.

- Normalisasi data: Dilakukan dengan metode MinMaxScaler agar seluruh nilai berada pada rentang [0,1]. Hal ini penting untuk mempercepat proses pelatihan dan menghindari bias pada nilai besar.
- Pembentukan data deret waktu: Data diubah menjadi urutan (*sequence*) agar model dapat belajar dari pola waktu sebelumnya, misalnya menggunakan 3 bulan terakhir untuk memprediksi bulan berikutnya.
- Pembagian data: Dataset dibagi menjadi dua bagian, yaitu data training (80%) untuk proses pelatihan dan data testing (20%) untuk pengujian model.

2.4. Pembentukan Model

Arsitektur Model

Tabel 2. Arsitektur Model

Lapisan	Jenis	Jumlah Unit / Shape	Aktivasi
Input Layer	Input	(n_steps, 1)	–
Hidden Layer 1	LSTM	64 unit	ReLU
Output Layer	Dense	1 neuron	Linear

Arsitektur model yang digunakan dalam penelitian ini adalah model Long Short-Term Memory (LSTM) dengan konfigurasi yang sederhana namun efisien untuk pemodelan deret waktu. Model ini terdiri dari tiga komponen utama, yaitu input layer, hidden layer berbasis LSTM, dan output layer.

Pada bagian *input layer*, data dimasukkan dalam bentuk urutan (*sequence*) dengan panjang tiga langkah waktu ($n_steps = 3$), sehingga model menerima data dengan dimensi (3, 1). Pemilihan jendela waktu ini bertujuan untuk memungkinkan model mempelajari hubungan temporal antar nilai pada periode sebelumnya.

Lapisan tersembunyi (*hidden layer*) terdiri dari satu lapisan LSTM dengan 64 unit neuron dan fungsi aktivasi ReLU. Lapisan ini berfungsi untuk menangkap informasi jangka panjang serta pola nonlinier pada dataset pendapatan dan stok penjualan. LSTM dipilih karena kemampuannya dalam mengatasi *vanishing gradient problem* dan lebih unggul dalam memodelkan data deret waktu dibandingkan metode konvensional seperti regresi linear.

Selanjutnya, model dilengkapi dengan *output layer* berupa lapisan Dense dengan satu neuron dan aktivasi linear. Lapisan ini menghasilkan satu nilai prediksi untuk periode berikutnya, sehingga model menghasilkan prediksi tunggal per iterasi (*single-step prediction*).

Hyperparameter

Tabel 3. Hyperparameter

Hyperparameter	Nilai
Epoch	200
Batch Size	default Keras (jika tidak ditentukan $\rightarrow 32$)
Optimizer	Adam
Loss Function	MSE (Mean Squared Error)

Hyperparameter	Nilai
Learning Rate	0.001 (default Adam)
LSTM Units	64
LSTM Activation	ReLU
Dense Units (Hidden Layer)	32
Dense Activation	ReLU
Output Neuron	1 (prediksi tunggal per iterasi)
Input Window (n_steps)	window (jumlah langkah input)

Model LSTM pada penelitian ini dilatih menggunakan 200 epoch, yaitu jumlah iterasi penuh ketika seluruh dataset dipelajari berulang kali oleh model. Jumlah epoch yang cukup besar ini dipilih untuk memastikan model mampu mengenali pola jangka panjang pada data deret waktu. Selama proses pelatihan, model menggunakan batch size default Keras, yaitu 32, yang dianggap ideal karena memberikan keseimbangan antara stabilitas gradient dan efisiensi komputasi. Pembaruan bobot dilakukan menggunakan optimizer Adam, sebuah algoritma adaptif yang secara luas digunakan dalam model deep learning karena kemampuannya mempercepat konvergensi dan bekerja dengan baik pada data non-linear seperti time series. Untuk mengukur tingkat kesalahan model, digunakan loss function Mean Squared Error (MSE) yang efektif karena memberi penalti lebih besar pada error yang tinggi, sehingga model dapat belajar melakukan prediksi dengan lebih presisi.

Proses pembelajaran ini dikendalikan oleh learning rate sebesar 0.001, yang merupakan nilai standar pada Adam dan terbukti stabil dalam mencegah pembaruan bobot yang terlalu drastis ataupun terlalu lambat. Arsitektur inti model menggunakan 64 unit pada layer LSTM, yang memungkinkan model mengingat pola historis dan dinamika data secara lebih mendalam. Aktivasi yang digunakan pada layer ini adalah ReLU, untuk mengatasi permasalahan *vanishing gradient* sekaligus mempercepat proses pelatihan. Setelah melalui layer LSTM, model dilanjutkan dengan layer dense berisi 32 unit yang berfungsi mengolah representasi fitur hasil LSTM sebelum menghasilkan prediksi akhir. Layer dense ini juga menggunakan fungsi aktivasi ReLU karena kemampuannya menangani hubungan non-linear secara efisien. Pada bagian output, model menghasilkan 1 neuron, yang digunakan untuk memprediksi nilai tunggal per iterasi, seperti pendapatan atau jumlah stok. Selain itu, model menggunakan input window (n_steps), yakni jumlah langkah waktu historis yang dijadikan input dalam satu batch prediksi, sehingga model dapat belajar berdasarkan jendela waktu tertentu yang merepresentasikan pola data sebelumnya.

2.5. Evaluasi Model

Evaluasi model dilakukan untuk menilai kemampuan LSTM dalam memprediksi pendapatan berdasarkan data historis. Dua metrik utama digunakan dalam penelitian ini, yaitu Mean Absolute Error (MAE) dan Mean Absolute Percentage Error (MAPE). Kedua metrik ini banyak digunakan dalam analisis deret waktu karena mampu merepresentasikan kesalahan prediksi secara kuantitatif dan mudah untuk diinterpretasikan[15].

Mean Absolute Error (MAE)

MAE mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi.

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

di mana:

- y_i = nilai aktual
- $\hat{y}_i$ = nilai prediksi
- n = jumlah data

Mean Absolute Percentage Error (MAPE)

MAPE digunakan untuk mengukur persentase kesalahan prediksi terhadap nilai aktual. Rumus MAPE adalah:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad s(2)$$


di mana:

- y_i = nilai aktual
- $\hat{y}_i$ = nilai hasil prediksi
- n = jumlah data pengujian

3. HASIL PENELITIAN DAN PEMBAHASAN

3.1. Hasil Prediksi Pendapatan


Berdasarkan hasil visualisasi prediksi pendapatan bulanan menggunakan model LSTM pada periode Oktober hingga Desember tahun 2023 dan 2024, terlihat adanya perbedaan pola prediksi antar tahun. Pada tahun 2023, hasil prediksi menunjukkan penurunan pendapatan yang cukup signifikan dari Oktober ke November, kemudian diikuti oleh peningkatan kembali pada bulan Desember. Sementara itu, pada tahun 2024, model memprediksi peningkatan pendapatan dari Oktober ke November, sebelum mengalami penurunan pada bulan Desember. Pola ini mengindikasikan bahwa model LSTM mampu menangkap dinamika fluktuasi pendapatan antar bulan, meskipun perubahan yang dihasilkan cenderung lebih halus dibandingkan variasi pendapatan aktual. Secara keseluruhan, hasil prediksi menunjukkan bahwa model dapat merepresentasikan tren pendapatan jangka pendek secara cukup baik pada kedua periode pengamatan.




Gambar 2. Grafik Prediksi Pendapatan 3 bulan kedepan 2023 dan 2024.

3.2. Hasil Prediksi Stok

Berdasarkan hasil visualisasi perbandingan antara data aktual dan hasil prediksi stok terjual pada periode Oktober hingga Desember tahun 2023 dan 2024, terlihat bahwa model LSTM mampu menghasilkan estimasi stok dengan pola yang relatif stabil. Pada tahun 2023, prediksi stok menunjukkan kecenderungan menurun secara bertahap dari Oktober hingga Desember, sementara data aktual memperlihatkan fluktuasi yang lebih tajam, khususnya penurunan signifikan pada bulan November dan peningkatan kembali pada bulan Desember. Perbedaan ini mengindikasikan bahwa model cenderung melakukan perataan (smoothing) terhadap fluktuasi ekstrem pada data aktual. Sementara itu, pada tahun 2024, hasil prediksi stok menunjukkan tren yang relatif konstan dengan sedikit peningkatan pada bulan November, sedangkan data aktual mengalami penurunan secara bertahap hingga Desember. Secara keseluruhan, hasil ini menunjukkan bahwa model LSTM mampu menangkap pola umum pergerakan stok terjual, meskipun masih memiliki keterbatasan dalam merepresentasikan perubahan stok yang bersifat fluktuatif dalam jangka pendek.



Gambar 3. Grafik Prediksi Stok 3 bulan kedepan 2023.



Gambar 4. Grafik Prediksi Stok 3 bulan kedepan 2024.


3.3. Evaluasi Model dengan MAE dan MAPE

Tabel 3. Hasil MAE dan MAPE.

Aspek Evaluasi	Pendapatan	Stok
MAE	2.002.652	369.33KG
MAPE	11.82%	5.00%
Kategori Akurasi	Baik ($\leq 10\% < 20\%$)	Sangat Baik ($< 10\%$)
Interpretasi	Tingkat kesalahan rata-rata sebesar 11.82% mengindikasikan bahwa model memiliki tingkat akurasi yang memadai dalam memprediksi pendapatan.	Kesalahan rata-rata 5% menunjukkan model mampu memperkirakan stok dengan sangat baik dan konsisten.
Kegunaan Model	Layak digunakan untuk mendukung keputusan bisnis terkait perencanaan pendapatan.	Dapat diandalkan untuk membantu perencanaan kebutuhan stok pada periode mendatang.

Tabel tersebut menunjukkan bahwa model LSTM memiliki kinerja sangat baik dalam memprediksi pendapatan dan stok berdasarkan nilai MAE dan MAPE. Pada prediksi pendapatan, nilai MAPE sebesar 11.82% menunjukkan tingkat kesalahan yang relatif rendah sehingga model cukup akurat untuk mendukung perencanaan pendapatan. Sementara itu, pada prediksi stok diperoleh nilai MAPE 5.00%, yang menandakan akurasi sangat tinggi dan konsistensi model dalam memperkirakan kebutuhan stok. Secara keseluruhan, hasil ini menunjukkan bahwa model LSTM layak digunakan sebagai alat bantu pengambilan keputusan pada UMKM.


3.4. Visualisasi Grafik Loss



Gambar 5. Grafik Loss Pendapatan.

Berdasarkan hasil pelatihan model LSTM, grafik loss menunjukkan bahwa nilai *training loss* mengalami penurunan secara konsisten seiring bertambahnya epoch, yang menandakan


bahwa proses pembelajaran model berlangsung dengan baik dan model mampu mempelajari pola data deret waktu secara bertahap. Sementara itu, nilai *validation loss* cenderung stabil dengan fluktuasi yang relatif kecil dan tidak menunjukkan peningkatan yang signifikan selama proses pelatihan. Pola ini mengindikasikan bahwa model memiliki kemampuan generalisasi yang cukup baik, di mana tidak terdapat indikasi overfitting yang kuat meskipun terjadi perbedaan nilai antara *training loss* dan *validation loss*. Dengan demikian, proses pelatihan model dapat dikatakan berjalan secara optimal dan model layak digunakan untuk tahap prediksi pendapatan.




Gambar 6. Grafik Loss Stok..

Grafik perkembangan loss selama pelatihan model LSTM untuk prediksi stok menunjukkan penurunan nilai *training loss* yang sangat signifikan pada fase awal pelatihan. Penurunan ini mengindikasikan bahwa model dengan cepat mampu mempelajari pola dasar dari data stok terjual. Setelah mencapai sekitar pertengahan epoch, nilai *training loss* cenderung melandai dan stabil hingga akhir pelatihan, yang menandakan bahwa proses pembelajaran telah mencapai kondisi konvergen. Sementara itu, nilai *validation loss* juga mengalami penurunan pada epoch awal dan kemudian berada pada nilai yang relatif rendah dengan fluktuasi kecil. Pola ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak menunjukkan indikasi overfitting yang berarti. Secara keseluruhan, grafik loss tersebut mengonfirmasi bahwa proses pelatihan model LSTM untuk prediksi stok berlangsung secara stabil dan optimal, sehingga model layak digunakan pada tahap pengujian dan implementasi prediksi.

3.5. Analisis Grafik Perbandingan Pendapatan Aktual dan Prediksi




Gambar 7. Grafik Perbandingan Pendapatan 2023.




Gambar 8. Grafik Perbandingan Pendapatan 2024.

Berdasarkan grafik perbandingan antara pendapatan aktual dan hasil prediksi pada periode Oktober hingga Desember tahun 2023 dan 2024, terlihat bahwa model LSTM mampu menghasilkan nilai prediksi yang relatif mendekati data aktual, meskipun masih terdapat selisih pada beberapa bulan. Pada tahun 2023, model cenderung memprediksi pendapatan lebih tinggi dibandingkan nilai aktual pada bulan Oktober dan November, sementara pada bulan Desember nilai prediksi berada di bawah pendapatan aktual. Pola serupa juga terlihat pada tahun 2024, di mana hasil prediksi lebih tinggi pada bulan Oktober dan November, namun lebih rendah pada bulan Desember. Selisih yang terjadi menunjukkan adanya kecenderungan model melakukan perataan terhadap fluktuasi pendapatan bulanan. Meskipun demikian, perbedaan antara pendapatan aktual dan prediksi masih berada dalam rentang yang wajar dan konsisten dengan hasil evaluasi kesalahan prediksi. Secara keseluruhan, grafik ini menunjukkan bahwa model LSTM memiliki kemampuan yang cukup baik dalam merepresentasikan pola pendapatan dan dapat digunakan sebagai dasar pendukung dalam pengambilan keputusan bisnis serta perencanaan keuangan pada usaha grosir telur.




Gambar 9. Grafik Perbandingan Stok 2023.



Gambar 10. Grafik Perbandingan Stok 2024.


Sementara itu, perbandingan stok aktual dan hasil prediksi pada tahun 2023 dan 2024 menunjukkan bahwa model LSTM mampu menghasilkan estimasi yang mendekati nilai aktual, meskipun terdapat selisih pada beberapa bulan. Pada tahun 2023, model cenderung melakukan overestimasi pada bulan Oktober dan November serta underestimasi pada bulan Desember, sedangkan pada tahun 2024 hasil prediksi relatif lebih tinggi dibandingkan stok aktual pada seluruh periode pengamatan. Meskipun demikian, selisih yang terjadi masih berada dalam batas wajar dan menunjukkan bahwa model LSTM cukup andal dalam memprediksi stok terjual.

3.6. Analisis Scatter Plot Korelasi



Gambar 11. Korelasi Prediksi Pendapatan.

Scatterplot korelasi antara nilai aktual dan hasil prediksi pendapatan pada periode 2023–2024 menunjukkan bahwa sebagian besar titik data berada relatif dekat dengan garis ideal ($y = x$), yang menandakan adanya hubungan yang cukup kuat antara nilai aktual dan nilai prediksi. Titik-titik yang berada di atas garis ideal menunjukkan kondisi di mana model melakukan overestimasi, sedangkan titik-titik di bawah garis tersebut merepresentasikan underestimasi. Secara umum, penyebaran titik yang tidak terlalu jauh dari garis ideal mengindikasikan bahwa model LSTM mampu merepresentasikan pola pendapatan aktual dengan cukup baik, meskipun masih terdapat deviasi pada beberapa periode tertentu.



Gambar 12. Korelasi Prediksi Stok

Scatterplot perbandingan antara stok aktual dan hasil prediksi pada periode 2023–2024 menunjukkan bahwa titik-titik data belum sepenuhnya berada pada garis ideal ($y = x$), yang menandakan masih adanya selisih antara nilai prediksi dan nilai aktual. Sebagian titik berada di atas garis ideal yang mengindikasikan terjadinya overestimasi, sementara titik lainnya berada di bawah garis tersebut yang menunjukkan underestimasi terhadap stok terjual. Meskipun demikian, pola sebaran titik masih mengikuti arah garis ideal, sehingga menunjukkan adanya korelasi positif antara stok aktual dan hasil prediksi. Hal ini mengindikasikan bahwa model LSTM mampu menangkap pola umum pergerakan stok dengan cukup baik, meskipun tingkat akurasi masih dapat ditingkatkan melalui penyempurnaan parameter dan proses pelatihan model.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma Long Short-Term Memory (LSTM) mampu memberikan kinerja prediksi yang cukup baik dalam memperkirakan pendapatan dan stok pada Toko Grosir Telur Rizki berdasarkan data deret waktu bulanan. Model LSTM yang dibangun dan dilatih menggunakan data periode dua tahun berhasil mempelajari pola historis pendapatan dan pergerakan stok, yang ditunjukkan melalui kedekatan antara nilai aktual dan hasil prediksi pada berbagai visualisasi perbandingan dan scatterplot. Evaluasi kinerja model menggunakan metrik Mean Absolute Error (MAE) dan Mean Absolute Percentage Error (MAPE) menunjukkan bahwa tingkat kesalahan prediksi berada pada kategori baik hingga sangat baik, dengan nilai MAPE sebesar 11.82% untuk variabel pendapatan dan 5.00% untuk variabel stok. Nilai tersebut mengindikasikan bahwa hasil prediksi model relatif mendekati nilai aktual, meskipun masih terdapat selisih pada beberapa periode akibat fluktuasi data.

Meskipun demikian, penelitian ini memiliki beberapa keterbatasan. Pertama, jumlah data historis yang digunakan relatif terbatas dan hanya mencakup data bulanan selama dua tahun, sehingga kemampuan model dalam menangkap pola jangka panjang yang lebih kompleks masih terbatas. Kedua, variabel yang digunakan dalam pemodelan hanya mencakup pendapatan dan stok terjual, tanpa mempertimbangkan faktor eksternal seperti perubahan harga pasar, kondisi musiman, kebijakan distribusi, atau faktor ekonomi makro yang berpotensi memengaruhi kinerja penjualan. Ketiga, evaluasi model belum dibandingkan secara langsung dengan metode prediksi lain, sehingga keunggulan LSTM dalam konteks ini belum dapat diukur secara komparatif. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan dataset dengan periode yang lebih panjang, menambahkan variabel eksternal yang relevan, serta melakukan perbandingan dengan metode prediksi lain guna meningkatkan akurasi dan generalisasi model.

Secara keseluruhan, hasil penelitian membuktikan bahwa metode LSTM dapat digunakan untuk membantu pemilik usaha dalam memprediksi pendapatan dan kebutuhan stok pada periode berikutnya. Prediksi yang dihasilkan mampu memberikan gambaran tren dan pola pergerakan data secara memadai, sehingga dapat dimanfaatkan sebagai dasar pendukung dalam perencanaan bisnis dan pengambilan keputusan operasional, khususnya dalam konteks UMKM dengan keterbatasan jumlah data historis.

DAFTAR PUSTAKA

- [1] R. D. Sanjaya, “Analisis Prediksi Profit Pada Toko Eska Dengan Metode Regresi Linear,” *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 12, no. 3, 2025, doi: 10.35957/jatisi.v12i3.12563.
- [2] M. P. Yadav and M. C. R. Barde, “Retail Real-Time Sales Prediction System Using LSTM and XGBoost,” *Int. J. Adv. Res. Comput. Commun. Eng. Impact Factor*, vol. 8, no. 4, pp. 201–207, 2025, doi: 10.17148/IJARCCCE.2025.14427.
- [3] Ulfarida Miftakhul Jannah, Nurmalitasari, Ridwan Dwi Irawan, “JTIM : Jurnal Teknologi

- Informasi dan Multimedia Analisis Prediksi Penjualan Isi Ulang Air Galon menggunakan Metode LSTM dan SARIMA,” vol. 7, no. 3, pp. 626–639, 2025.
- [4] M. Ula, V. Ilhadi, and Z. M. Sidek, “Comparing Long Short-Term Memory and Random Forest Accuracy for Bitcoin Price Forecasting,” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 23, no. 2, pp. 259–272, 2024, doi: 10.30812/matrik.v23i2.3267.
 - [5] D. Brykin, “Sales Forecasting Models: Comparison between ARIMA, LSTM and Prophet,” *J. Comput. Sci.*, vol. 20, no. 10, pp. 1222–1230, 2024, doi: 10.3844/jcssp.2024.1222.1230.
 - [6] S. B. Timothy, C. Imam, and Y. Novanto, “Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 1101–1107, 2023, [Online]. Available: <http://j-ptiik.ub.ac.id>
 - [7] A. Rosyd, A. Irma Purnamasari, and I. Ali, “Penerapan Metode Long Short Term Memory (Lstm) Dalam Memprediksi Harga Saham Pt Bank Central Asia,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 501–506, 2024, doi: 10.36040/jati.v8i1.8440.
 - [8] A. Fajar Risnandar, F. Supriadi, and D. Indra Junaedi, “Prediksi Harga Saham Indofood Menggunakan Long Short-Term Memory,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, pp. 4694–4701, 2025, doi: 10.36040/jati.v9i3.13321.
 - [9] P. Dan, A. Harga, and M. Di, “Pendekatan Berbasis Gru Dan Lstm,” vol. 9, no. 5, pp. 7600–7607, 2025.
 - [10] J. Cahyani, S. Mujahidin, and T. Palyus, “Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional,” vol. 11, no. 2, pp. 346–357, 2023, doi: 10.26418/justin.v11i2.57395.
 - [11] X. Wen and W. Li, “Time Series Prediction Based on LSTM-Attention-LSTM Model,” *IEEE Access*, vol. 11, pp. 48322–48331, 2023, doi: 10.1109/ACCESS.2023.3276628.
 - [12] P. Isaac Ritharson, J. Anitha, and S. I. Alex Pandian, “A Web-based Real-time Sales Data Analysis using LSTM Model for Better Insight,” *2023 9th Int. Conf. Adv. Comput. Commun. Syst. ICACCS 2023*, no. May, pp. 1060–1064, 2023, doi: 10.1109/ICACCS57279.2023.10112837.
 - [13] W. Ternate, M. Utara, and T. Handhayani, “Implementasi Algoritma LSTM untuk Memprediksi,” vol. 8, no. 1, pp. 26–32, 2024, doi: 10.55886/infokom.v8i1.836.
 - [14] E. Verianto, “MENCEGAH OVERFITTING PADA MODEL PREDIKSI,” vol. 9, no. 2, pp. 195–204, 2024.
 - [15] H. Kopi, J. Pendek, and D. A. N. Jangka, “Penerapan lstm dalam deep learning untuk prediksi harga kopi jangka pendek dan jangka panjang,” vol. 10, no. 1, pp. 554–564, 2025.