

Forecasting Permintaan Persediaan Berbasis Long Short-Term Memory untuk Penentuan Safety Stock dan Reorder Point

Eka Fatmawati*, Endah Sudarmilah

Teknik Informatika, Komunikasi dan Informatika, Universitas Muhammadiyah Surakarta, Surakarta, Indonesia

Email: ^{1,*}l200220232@student.ums.ac.id, ²Author2@email.com,

Email Penulis Korespondensi: l200220232@student.ums.ac.id*

Submitted: 07/03/2026; Accepted: 26/03/2026; Published: 31/03/2026

Abstrak— Ketidakseimbangan antara ketersediaan stok dan fluktuasi permintaan sering menyebabkan overstock maupun stockout dalam manajemen persediaan ritel. Penelitian ini bertujuan untuk menerapkan metode *Long Short-Term Memory* (LSTM) dalam peramalan permintaan. Peramalan ini digunakan sebagai dasar penentuan *Safety Stock* (SS) dan *Reorder Point* (ROP) pada tiga kategori produk ritel: susu, sabun, dan *frozen food*. Data historis penjualan digunakan untuk menghasilkan prediksi permintaan tiga bulan ke depan. Hasil prediksi dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE), dan *Root Mean Squared Error* (RMSE). Hasil evaluasi menunjukkan bahwa model LSTM menghasilkan tingkat akurasi yang baik pada seluruh kategori produk. Pada kategori susu, rata-rata nilai MAPE sebesar 4,53%, dan pada sabun sebesar 5,23%. Kedua nilai ini tergolong sangat baik. Sementara itu, *frozen food* memiliki nilai MAPE sebesar 12,08%, yang termasuk kategori baik. Berdasarkan hasil peramalan tersebut, parameter pengendalian persediaan dihitung menggunakan pendekatan *Safety Stock* dan *Reorder Point*. Kategori susu menunjukkan nilai rata-rata SS dan ROP tertinggi. Hal ini mencerminkan volume permintaan yang lebih besar dibandingkan kategori lainnya. Di sisi lain, kategori *frozen food* memperlihatkan variasi ROP yang relatif lebih tinggi antar produk. Hasil penelitian ini menunjukkan bahwa integrasi metode LSTM dengan model pengendalian persediaan dapat mendukung perumusan kebijakan stok yang lebih terukur dan berbasis data dalam pengelolaan persediaan ritel. Penelitian ini memberikan kontribusi berupa integrasi metode deep learning dengan model pengendalian persediaan yang menghasilkan kebijakan stok yang lebih terukur dan aplikatif.

Kata Kunci: Long Short-Term Memory (LSTM), Peramalan Deret Waktu, Optimasi Persediaan, Safety Stock, Reorder Point

Abstract— The imbalance between stock availability and demand fluctuations often leads to overstock and stockout situations in retail inventory management. This study aims to apply the Long Short-Term Memory (LSTM) method in demand forecasting. The forecasts serve as the basis for determining Safety Stock (SS) and Reorder Point (ROP) across three retail product categories: milk, soap, and frozen food. Historical sales data were used to generate demand predictions for the next three months. The forecasting results were evaluated using Mean Absolute Percentage Error (MAPE), Mean Absolute Error (MAE), and Root Mean Squared Error (RMSE). The evaluation results indicate that the LSTM model produced good accuracy levels across all product categories. In the milk category, the average MAPE value was 4.53%, and in the soap category it was 5.23%, both of which are classified as very good. Meanwhile, frozen food yielded a MAPE value of 12.08%, which falls under the good category. Based on these forecasting results, inventory control parameters were calculated using the Safety Stock and Reorder Point approach. The milk category exhibited the highest average SS and ROP values, reflecting a higher demand volume compared to the other categories. On the other hand, the frozen food category showed relatively higher ROP variation across products. The findings of this study demonstrate that integrating the LSTM method with inventory control models can support the formulation of more measurable and data-driven stock policies in retail inventory management. This research contributes through the integration of deep learning methods with inventory control models, resulting in stock policies that are more structured and practically applicable, which can lead to improved efficiency and reduced waste in inventory management.

Keywords: Long Short-Term Memory (LSTM), Time Series Forecasting, Inventory Optimization, Safety Stock, Reorder Point

1. PENDAHULUAN

Meskipun berbagai penelitian telah dilakukan dalam bidang peramalan permintaan dan manajemen persediaan, sebagian besar masih menggunakan metode konvensional seperti ARIMA dan Moving Average yang memiliki keterbatasan dalam menangkap pola non-linear. Selain itu, penelitian terdahulu umumnya hanya berfokus pada satu kategori produk dan belum mengintegrasikan hasil peramalan secara langsung dengan perhitungan kebijakan persediaan seperti safety stock dan reorder point. Oleh karena itu, diperlukan pendekatan yang mampu mengatasi kompleksitas pola permintaan sekaligus menghasilkan keputusan operasional yang aplikatif. Manajemen persediaan menjadi isu krusial dalam distribusi produk dengan karakteristik permintaan yang beragam, seperti makanan *frozen*, sabun, dan susu [1], [2]. Data historis penjualan menunjukkan adanya fluktuasi yang signifikan pada tiap kategori produk. Produk makanan *frozen* memiliki risiko tinggi terhadap kerugian akibat *overstock* karena sifatnya yang mudah rusak dan membutuhkan biaya penyimpanan dingin yang relatif besar [3], [4]. Produk sabun, walaupun bersifat tahan lama, tetap menghadapi tantangan dari sisi akurasi prediksi permintaan sehingga potensi kelebihan stok masih mungkin terjadi dan berdampak pada tingginya biaya simpan [5]. Produk susu cenderung memiliki pola penjualan stabil dengan volume menengah, namun berisiko menghadapi *stock out* apabila permintaan tiba-tiba melonjak, misalnya pada musim tertentu. Ketidaktersediaan stok pada produk *frozen* dapat berdampak lebih serius, tidak hanya pada hilangnya peluang penjualan, tetapi juga pada kerugian finansial akibat produk yang kedaluwarsa [3]. Di sisi lain, risiko *overstock* berimplikasi langsung terhadap peningkatan biaya simpan, baik dalam bentuk biaya gudang, biaya modal, maupun risiko penyusutan nilai barang [6]. Selain itu, risiko *stock out* dapat mengurangi kepuasan pelanggan dan menurunkan penjualan,

hususnya pada ketiga produk tersebut. Kondisi ini menuntut adanya sistem manajemen persediaan yang mampu menjaga keseimbangan antara ketersediaan produk dengan biaya penyimpanan yang efisien [1], [5]. Berdasarkan kondisi tersebut, tujuan penelitian ini adalah mengembangkan pendekatan kuantitatif berbasis data penjualan historis untuk mengidentifikasi pola permintaan dan merumuskan kebijakan persediaan yang optimal [8]. Dengan memanfaatkan metode peramalan, penelitian diarahkan untuk menghitung kebutuhan *safety stock*, *reorder point*, dan EOQ pada masing-masing kategori produk [9], [10]. Hasil yang diharapkan adalah tercapainya *service level* yang sesuai dengan target perusahaan, meminimalkan risiko *stock out*, sekaligus menekan biaya *overstock*. Pada akhirnya, penelitian ini diharapkan dapat memberikan rekomendasi kebijakan persediaan yang lebih adaptif, efisien, dan aplikatif bagi manajemen rantai pasok produk makanan *frozen*, sabun, dan susu [11].


Penelitian terdahulu mengungkapkan bahwa sejumlah penelitian telah mengkaji manajemen persediaan dengan berbagai pendekatan [3] dalam penelitian berjudul "*Comparative Analysis of Time Series Methods LSTM and ARIMA for Predicting Inventory Availability*" membandingkan kinerja ARIMA dan LSTM untuk produk makanan beku, dan menemukan bahwa LSTM menghasilkan kesalahan yang lebih kecil untuk produk dengan fluktuasi tinggi. [9] dalam "*Penentuan Reorder Point dan Safety Stock pada Consumable Material Berdasarkan Peramalan Menggunakan Artificial Neural Network*" menggunakan Jaringan Saraf Tiruan untuk meramalkan permintaan material consumable dan berhasil menghitung Safety Stock serta Reorder Point. Beberapa penelitian lain juga memberikan kontribusi signifikan [4] dalam "*Forecasting and Modelling of Food Demand Supply Chain using Machine Learning*" mengeksplorasi penggunaan *machine learning* untuk peramalan permintaan pangan, sementara [6] menyelidiki pendekatan klasik dan *machine learning* untuk peramalan dan perencanaan persediaan. Studi-studi terkait lainnya termasuk [2] tentang "*Demand Forecasting For Improved Inventory Management in Small and Medium-Sized Businesses*", [5] mengenai "*Improvement of Inventory Management and Demand Forecasting by Big Data Analytics in Supply Chain*", serta [10] yang mengembangkan "*Intelligent inventory prediction: A machine learning framework using random forest for inventory forecasting*". Penelitian-penelitian ini semakin memperkuat pentingnya peramalan yang akurat untuk pengelolaan persediaan yang optimal.

Berdasarkan tinjauan tersebut, teridentifikasi celah penelitian. Sebagian besar penelitian sebelumnya mengenai manajemen persediaan lebih menitikberatkan pada penggunaan metode *forecasting* tradisional, seperti ARIMA, *Exponential Smoothing*, atau *Moving Average* [12], [13], yang cenderung kurang mampu menangkap pola kompleks fluktuasi permintaan multi-produk. Selain itu, penelitian terdahulu umumnya fokus pada satu kategori produk saja, tanpa mempertimbangkan perbedaan karakteristik antarproduk dengan risiko berbeda (makanan *frozen*, sabun, dan susu). Celah lainnya adalah keterbatasan integrasi antara hasil peramalan dengan perhitungan operasional manajemen stok seperti *safety stock*, *reorder point*, dan EOQ, sehingga rekomendasi yang dihasilkan sering kali masih bersifat konseptual, belum operasional dan aplikatif bagi pengambil keputusan. Penelitian ini menawarkan kontribusi baru dengan mengintegrasikan pendekatan *machine learning* berbasis *Long Short-Term Memory* (LSTM) yang unggul dalam menangani data deret waktu dengan pola non-linear dan jangka panjang, ke dalam kerangka manajemen persediaan multi-produk dengan karakteristik berbeda. Pendekatan ini memungkinkan akurasi peramalan yang lebih tinggi dibandingkan metode konvensional, yang kemudian divalidasi menggunakan metrik kuantitatif, yaitu *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) untuk menjamin reliabilitas hasil [14]. Selain itu, penelitian ini secara langsung menghubungkan output peramalan dengan kebijakan persediaan yang konkret, mencakup perhitungan *safety stock*, *reorder point*, dan EOQ [15], sehingga menghasilkan strategi stok yang efektif dan meminimalisir *stockout* dan *overstock* produk pada persediaan yang dapat mengurangi *opportunity cost* [16].

2. METODOLOGI PENELITIAN

2.1. Pengumpulan Data Historis

Penelitian ini dari asumsi pada Gambar 1 metodologi penelitian bahwa fluktuasi permintaan merupakan faktor utama yang memengaruhi kebutuhan *safety stock* dalam manajemen persediaan [1]. Oleh karena itu, tahap pertama adalah melakukan analisis peramalan permintaan menggunakan metode LSTM, sebuah algoritma *machine learning* yang efektif dalam menangkap pola jangka panjang pada data deret waktu. Data historis penjualan produk makanan *frozen*, sabun, dan susu digunakan sebagai input model [17]. Hasil peramalan kemudian divalidasi dengan ukuran akurasi kuantitatif, yaitu MAPE, MAE dan RMSE untuk memastikan tingkat keandalan model. Tahap berikutnya adalah mengintegrasikan hasil peramalan ke dalam perhitungan manajemen persediaan, yang mencakup *safety stock*, *reorder point*, dan EOQ [9], [10]. Dengan demikian, penelitian ini tidak hanya menghasilkan prediksi permintaan, tetapi juga memberikan kebijakan operasional yang konkret bagi pengelolaan stok [18]. Pendekatan ini memungkinkan perusahaan untuk menyeimbangkan antara *service level* yang tinggi dengan efisiensi biaya penyimpanan [5].



Gambar 1. Metodologi Penelitian

Tahap awal penelitian dimulai dengan pengumpulan data historis penjualan dari berbagai kategori produk, seperti makanan *frozen*, sabun, dan susu. Data ini menjadi dasar utama bagi proses peramalan karena mencerminkan pola permintaan aktual dari periode sebelumnya. Pengumpulan data yang komprehensif dan akurat memastikan bahwa model peramalan dapat menangkap variabilitas permintaan yang sesungguhnya dan menghasilkan prediksi yang lebih reliable untuk pengambilan keputusan persediaan [19].

2.2. Preprocessing Data

Setelah data terkumpul, dilakukan *preprocessing* untuk memastikan kualitas data sebelum masuk ke tahap pemodelan. Proses ini meliputi pembersihan data dari duplikasi atau nilai kosong, normalisasi untuk menyeragamkan skala variabel, serta transformasi agar sesuai dengan format deret waktu yang dibutuhkan model. Tahap *preprocessing* merupakan langkah krusial yang secara signifikan mempengaruhi kualitas output model, sehingga perhatian khusus harus diberikan untuk memastikan data yang diproses sudah dalam kondisi optimal dan bebas dari anomali yang dapat mengganggu pembelajaran model [8].

2.3. Peramalan dengan LSTM

Data yang telah diproses kemudian digunakan dalam pemodelan menggunakan metode LSTM. Metode ini dipilih karena kemampuannya dalam mengenali pola non-linear serta menangkap dependensi jangka panjang pada data *time series*, sehingga menghasilkan prediksi permintaan yang lebih akurat dibandingkan metode konvensional. Algoritma LSTM bekerja dengan mekanisme gating yang memungkinkan jaringan untuk selektif menyimpan dan menghapus informasi, sehingga mampu menangani data *time series* dengan jangka panjang yang kompleks dan menghasilkan peramalan yang lebih robust dibandingkan dengan metode tradisional [3]. Dalam penelitian ini, model *Long Short-Term Memory* yang digunakan memiliki arsitektur yang sederhana namun efektif untuk data deret waktu. Model terdiri dari satu lapisan LSTM (single LSTM layer) dan satu lapisan Dense sebagai output layer. Jumlah unit neuron pada lapisan LSTM berbeda untuk setiap kategori produk, yaitu 50 unit untuk kategori *frozen*, serta 32 unit untuk kategori sabun dan susu. Model dilatih menggunakan fungsi loss MSE dan dioptimasi dengan algoritma Adam (*Adaptive Moment Estimation*). Pada kategori sabun dan susu, digunakan *learning rate* sebesar 0,01 untuk mempercepat proses konvergensi. Jumlah iterasi pelatihan (*epoch*) ditentukan berbeda untuk setiap kategori, yaitu 50 epoch pada produk *frozen* dan 200 epoch pada produk sabun dan susu, menyesuaikan dengan karakteristik data. Selain itu, batch size sebesar 8 digunakan pada kategori *frozen*, sedangkan pada kategori lainnya menggunakan nilai default dari Keras. Untuk pembagian data, digunakan metode *train-test split* dengan rasio 80:20 pada kategori *frozen*, di mana 80% data digunakan untuk pelatihan dan 20% untuk pengujian. Sementara itu, pada kategori sabun dan susu, evaluasi dilakukan menggunakan *in-sample evaluation* karena keterbatasan jumlah data historis yang tersedia.

2.4. Validasi Hasil Peramalan

Model LSTM yang telah dilatih divalidasi menggunakan metrik kuantitatif seperti MAPE, MAE, dan RMSE. Validasi ini dilakukan untuk mengukur tingkat akurasi dan reliabilitas prediksi sebelum model diterapkan pada pengambilan keputusan persediaan. Ketiga metrik evaluasi ini dipilih karena mampu memberikan perspektif berbeda dalam menilai performa model, MAPE menunjukkan persentase kesalahan relatif, MAE mengukur magnitude kesalahan rata-rata, dan RMSE sensitif terhadap kesalahan besar, sehingga secara komprehensif menggambarkan kualitas peramalan [20]. Perhitungan MAPE ditunjukkan pada Persamaan (1):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100\% \quad (1)$$

dengan keterangan:

A_i = nilai aktual ke- i ,

F_i = nilai prediksi ke- i ,

n = jumlah data.

MAPE digunakan untuk mengetahui persentase rata-rata kesalahan prediksi, sehingga semakin kecil nilai MAPE maka semakin baik akurasi model. Perbedaan utama antara MAPE dan MAE terletak pada cara pengukuran, MAPE mengevaluasi persentase kesalahan relatif terhadap nilai aktual sehingga lebih mudah dipahami dalam konteks bisnis, sementara MAE mengukur kesalahan absolut tanpa memperhitungkan besaran nilai sebenarnya, menjadikan kedua metrik ini saling melengkapi dalam evaluasi peramalan. Selanjutnya, tingkat kesalahan kuadrat rata-rata diukur menggunakan MAE sebagaimana ditunjukkan pada Persamaan (2):

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

dengan keterangan:

n = jumlah data,

Y_i = nilai aktual ke- i ,

$\hat{Y}_i$ = nilai prediksi ke- i ,

$|Y_i - \hat{Y}_i|$ = selisih absolut antara nilai aktual dan prediksi.

MAE digunakan untuk mengukur rata-rata besar kesalahan prediksi tanpa memperhatikan arah kesalahan (positif atau negatif). Nilai MAE yang lebih kecil menunjukkan bahwa hasil prediksi semakin mendekati nilai aktual. Untuk memberikan interpretasi tambahan terhadap tingkat kesalahan model, digunakan pula RMSE sebagaimana ditunjukkan pada Persamaan (3):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (3)$$

dengan keterangan:

Y_i = nilai aktual ke- i ,

$\hat{Y}_i$ = nilai prediksi ke- i ,

n = jumlah data.

RMSE menyajikan besaran kesalahan dalam satuan yang sama dengan data aslinya, namun lebih sensitif terhadap *outlier* karena menggunakan kuadrat selisih. Kombinasi ketiga metrik ini memastikan evaluasi model yang holistik, MAPE memberikan perspektif persentase, MAE mengukur tingkat kesalahan rata-rata, dan RMSE mendeteksi adanya *outlier* atau prediksi ekstrem yang dapat berdampak besar terhadap akurasi peramalan persediaan. Dengan demikian, penggunaan ketiga metrik secara simultan memungkinkan penilaian performa model yang lebih komprehensif dan mengurangi potensi bias apabila evaluasi hanya didasarkan satu indikator saja.

2.5. Analisis Hasil dan Simulasi

Setelah hasil peramalan tervalidasi, dilakukan analisis lanjutan dan simulasi untuk mengevaluasi implikasi prediksi terhadap *service level* dan biaya simpan. Tahap ini membantu memahami dampak kebijakan persediaan berdasarkan dinamika permintaan dan kapasitas penyimpanan. Simulasi ini memungkinkan pengambil keputusan untuk menguji berbagai kebijakan persediaan dan melihat dampak terhadap *service level* dan biaya simpan, sehingga dapat memilih strategi yang optimal dan disesuaikan dengan kondisi bisnis yang dinamis [6].

2.6. Perhitungan Persediaan

Berdasarkan hasil prediksi yang telah diverifikasi, perhitungan ini difokuskan pada keseimbangan antara ketersediaan produk dan efisiensi biaya operasional. Ketiga parameter ini bekerja secara sinergis, *safety stock* memberikan perlindungan terhadap ketidakpastian, *reorder point* menentukan waktu pemesanan yang tepat, dan EOQ mengoptimalkan jumlah pesanan untuk meminimalkan total biaya persediaan sambil mempertahankan tingkat layanan yang memuaskan [9]. *Safety stock* dihitung menggunakan Persamaan (4) sebagai langkah antisipatif terhadap fluktuasi permintaan dan lead time.

$$SS = Z \times \sigma \times \sqrt{L} \quad (4)$$

dengan keterangan:

SS = Safety Stock,

Z = nilai Z-score berdasarkan tingkat layanan,

σ = standar deviasi permintaan,

L = lead time.

Setelah *safety stock* ditentukan, *reorder point* dihitung menggunakan Persamaan (5).

$$ROP = (D \times L) + SS \quad (5)$$

dengan keterangan:

ROP = titik pemesanan ulang,

D = rata-rata permintaan per periode,

L = lead time,

SS = safety stock.

Selanjutnya, jumlah pemesanan optimal ditentukan menggunakan pendekatan *Economic Order Quantity* (EOQ) seperti ditunjukkan pada Persamaan (6).

$$Q = \sqrt{\frac{2DS}{H}} \quad (6)$$

dengan keterangan:

Q = jumlah pemesanan optimal,

D = kebutuhan tahunan,


S = biaya pemesanan per sekali order,

H = biaya penyimpanan per unit per tahun.

Melalui penerapan ketiga parameter ini, sistem pengendalian persediaan dapat dirancang secara lebih efisien untuk mencegah risiko *overstock* maupun *stock out*. Implementasi terintegrasi dari *safety stock*, *reorder point*, dan EOQ menciptakan sistem yang responsif terhadap perubahan permintaan dan efisien dalam penggunaan sumber daya, yang pada akhirnya berkontribusi pada peningkatan profitabilitas dan kepuasan pelanggan melalui peningkatan ketersediaan produk. Pendekatan ini juga memungkinkan perusahaan menyeimbangkan antara biaya penyimpanan dan *service level*, sehingga keputusan persediaan menjadi lebih strategis dan berbasis data.

2.7. Visualisasi Rekomendasi Kebijakan

Tahap akhir adalah mengintegrasikan hasil analisis peramalan dan perhitungan persediaan untuk menghasilkan visualisasi rekomendasi kebijakan. Visualisasi ini disusun agar dapat digunakan sebagai dasar pengambilan keputusan yang menjaga ketersediaan produk sekaligus menekan biaya logistik. Sebagai tahap lanjutan setelah proses peramalan dan perhitungan kebutuhan persediaan, penelitian ini juga menghasilkan rancangan antarmuka sistem dalam berbasis web [18]. Wireframe ini disusun untuk memvisualisasikan bagaimana hasil analisis dan prediksi dapat diimplementasikan dalam praktik operasional.



Gambar 2. Tampilan Halaman Input Data

Tampilan halaman Input Data. Tampilan Halaman Input Data dapat dilihat pada Gambar 2, sebagai sarana untuk memasukkan atau memperbarui data historis penjualan yang menjadi dasar pemodelan LSTM [21]. Halaman ini berguna untuk melakukan *forecasting* dengan cara pengguna memasukkan rekap data stock barang terbaru dengan format file *xlsx* yang kemudian tekan tombol jalankan *forecasting*, lalu otomatis memproses data kemudian akan keluar hasil *forecastingnya*.

3. HASIL

Bab ini menyajikan hasil pengolahan data dan evaluasi model *Long Short-Term Memory* dalam memprediksi permintaan pada tiga kategori produk, yaitu makanan frozen, sabun, dan susu. Hasil yang disajikan meliputi evaluasi performa model menggunakan *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE), dan *Root Mean Squared Error* (RMSE), hasil peramalan permintaan, serta perhitungan kebijakan persediaan.

3.1 Evaluasi Performa Model LSTM

Berdasarkan Tabel 1, diperoleh nilai evaluasi model LSTM untuk masing-masing produk. Produk susu memiliki nilai MAPE sebesar 4,52%, MAE sebesar 2,90, dan RMSE sebesar 3,75. Produk sabun memiliki nilai MAPE sebesar 6,09%, MAE sebesar 1,09, dan RMSE sebesar 1,42. Sementara itu, produk frozen memiliki nilai MAPE sebesar 12,08%, MAE sebesar 1,28, dan RMSE sebesar 1,67.

3.2 Hasil Forecasting Permintaan Produk

a. Produk Frozen

Gambar 3 menunjukkan hasil peramalan permintaan produk *frozen* selama tiga bulan ke depan. Nilai prediksi untuk masing-masing produk berada pada kisaran yang relatif stabil. Gambar 4 menunjukkan nilai MAPE untuk masing-masing produk *frozen*. Nilai MAPE yang diperoleh berada pada rentang 8,28% hingga 16,11%.

b. Produk Sabun

Gambar 6 menunjukkan hasil peramalan permintaan produk sabun selama tiga bulan ke depan. Nilai prediksi mengalami fluktuasi ringan pada setiap periode. Gambar 7 menunjukkan nilai MAPE untuk masing-masing produk sabun, dengan seluruh nilai berada di bawah 10%.

c. Produk Susu

Gambar 9 menunjukkan hasil peramalan permintaan produk susu selama tiga bulan ke depan. Nilai prediksi menunjukkan kecenderungan meningkat pada setiap periode. Gambar 10 menunjukkan nilai MAPE untuk masing-masing produk susu, dengan nilai berada pada kisaran 3% hingga 5%.

3.3 Hasil Perhitungan Kebijakan Persediaan

Berdasarkan hasil peramalan, dilakukan perhitungan kebijakan persediaan menggunakan metode *Safety Stock*, *Reorder Point*, dan *EOQ*. Hasil perhitungan ditampilkan pada Tabel 2, yang memuat nilai *Safety Stock*, *Reorder Point*, dan *EOQ* untuk masing-masing produk pada ketiga kategori.

4. PEMBAHASAN

Bab ini menyajikan pembahasan evaluasi performa model LSTM dalam memprediksi permintaan tiga kategori produk, yaitu makanan *frozen*, sabun, dan susu. Evaluasi dilakukan menggunakan MAPE, MAE, dan RMSE. Selain menyajikan hasil kuantitatif, bagian ini juga menganalisis stabilitas model, karakteristik data, serta implikasi manajerial terhadap sistem pengendalian persediaan.

4.1 Interpretasi Performa Model

Berdasarkan Tabel 1, model menunjukkan performa sangat baik pada produk susu dengan nilai MAPE sebesar 4,52%. Secara teoritis, nilai MAPE kurang dari 10% dikategorikan sebagai *highly accurate forecasting*. Evaluasi menunjukkan pola historis permintaan susu memiliki struktur temporal yang dapat dipelajari secara efektif oleh LSTM. Produk sabun menghasilkan MAPE sebesar 6,09%, yang pada kategori baik. Nilai ini menunjukkan model mampu menangkap dinamika permintaan dengan tingkat deviasi rata-rata di bawah 7% dari nilai aktual.

Table 1. Hasil Evaluasi Model LSTM

Produk	MAPE (%)	MAE	RMSE
Frozen	12,08	1,28	1,67
Sabun	6,09	1,09	1,42
Susu	4,52	2,90	3,75

Sebaliknya, produk *frozen* memiliki MAPE sebesar 12,08%. Meskipun lebih tinggi dibandingkan dua produk lainnya, nilai tersebut masih berada dalam kategori *reasonable forecasting* (10–20%). Hal ini mengindikasikan bahwa karakteristik permintaan produk *frozen* cenderung lebih volatil dan mengandung *noise* yang lebih tinggi. Nilai MAE dan RMSE menunjukkan pola konsisten dengan MAPE. Produk susu memiliki MAE

sebesar 2,90 unit, menunjukkan secara rata-rata prediksi menyimpang kurang dari tiga unit dari nilai aktual. Perbedaan MAE dan RMSE pada ketiga produk relatif kecil, yang mengindikasikan bahwa distribusi error tidak didominasi oleh *outlier ekstrem*. Temuan ini memperkuat indikasi bahwa model memiliki stabilitas prediktif baik.

4.2 Analisis Karakteristik Data dan Stabilitas Model

Perbedaan performa antar produk tidak hanya dipengaruhi oleh arsitektur model, tetapi juga oleh karakteristik data *time series* masing-masing. Produk susu menunjukkan pola permintaan yang relatif stabil dengan fluktuasi moderat. Stabilitas ini memungkinkan LSTM mengidentifikasi pola jangka panjang (*long-term dependencies*) secara optimal. Produk sabun memiliki variasi musiman ringan, namun tetap berada dalam rentang yang dapat dimodelkan dengan baik. Sebaliknya, produk *frozen* menunjukkan variabilitas yang lebih tinggi. Fluktuasi ini kemungkinan disebabkan oleh faktor *eksternal* seperti promosi, diskon musiman, atau perubahan preferensi konsumen. Dalam konteks *deep learning*, data dengan varians tinggi cenderung meningkatkan nilai error karena model harus mengakomodasi pola yang kurang konsisten. Hal ini menunjukkan bahwa akurasi model tidak hanya ditentukan oleh kompleksitas algoritma, tetapi juga oleh struktur dan kualitas data input.

4.3 Perbandingan dengan Penelitian Sebelumnya


Hasil penelitian ini menunjukkan bahwa LSTM mampu menghasilkan MAPE di bawah 15% untuk seluruh kategori produk. Beberapa penelitian sebelumnya melaporkan bahwa model *deep learning* pada data ritel umumnya menghasilkan MAPE pada kisaran 8–18%, tergantung pada stabilitas data capaian MAPE 4,52% pada produk susu dan 6,09% pada produk sabun, penelitian ini menunjukkan performa yang lebih baik dibandingkan rata-rata studi sejenis pada skala UMKM. Kontribusi utama penelitian ini tidak hanya terletak pada penggunaan LSTM, tetapi juga pada integrasi hasil peramalan dengan metode manajemen persediaan seperti *Safety Stock*, *Reorder Point*, dan *EOQ*. Pendekatan terintegrasi ini jarang dibahas secara simultan dalam penelitian sebelumnya, yang umumnya berhenti pada tahap evaluasi akurasi model. Penelitian ini memberikan kontribusi praktis berupa kerangka sistem pendukung keputusan berbasis *machine learning* untuk pengendalian persediaan.

4.4 Implikasi Manajerial

Dari perspektif manajemen operasional, akurasi peramalan dengan MAPE kurang dari 10% memiliki dampak signifikan terhadap efisiensi persediaan. Kesalahan prediksi yang rendah akan mengurangi risiko *overstock*, Meminimalkan kemungkinan *stockout*, Mengoptimalkan biaya penyimpanan, Meningkatkan perputaran persediaan. Produk *frozen* yang memiliki MAPE lebih tinggi memerlukan kebijakan *safety stock* yang lebih konservatif. Hal ini menunjukkan bahwa kebijakan persediaan sebaiknya disesuaikan dengan tingkat ketidakpastian permintaan masing-masing produk. Pendekatan berbasis LSTM memungkinkan pengambilan keputusan yang lebih adaptif dibandingkan metode rata-rata historis konvensional.

4.5 Evaluasi Hasil Peramalan Produk Frozen Food

Bagian ini bertujuan untuk mengevaluasi kinerja model peramalan secara kuantitatif dan interpretatif terhadap lima produk *frozen*. Evaluasi tidak hanya menitikberatkan pada nilai akurasi statistik, tetapi juga pada kemampuan model dalam merepresentasikan pola permintaan historis serta konsistensi prediksi jangka pendek. Dengan demikian, pembahasan difokuskan pada analisis trend hasil forecasting, pengukuran tingkat kesalahan menggunakan MAPE, dan interpretasi stabilitas permintaan agregat sebagai dasar pengambilan keputusan operasional.



Gambar 3. Visualisasi Trend Forecast untuk Produk Frozen


a. Analisis Trend Forecasting 3 Bulan

Berdasarkan Gambar 3, hasil peramalan lima produk *frozen* untuk tiga bulan ke depan menunjukkan pola yang relatif stabil dengan fluktuasi sangat kecil. Hal ini mengindikasikan bahwa permintaan jangka pendek cenderung konsisten tanpa perubahan signifikan. NAGET SALAM 500G memiliki volume tertinggi, sekitar 35 unit per bulan, dengan sedikit kenaikan pada bulan kedua dan penurunan ringan pada bulan ketiga, namun tetap stabil. NAGET SO ECO 500G berada pada kisaran 16–17 unit per bulan dengan pola yang datar. NAGET NGETOP 500G rata-rata sekitar 9 unit per bulan dan menunjukkan stabilitas yang baik. Sementara itu, NAGET SALAM 250G dan NAGET KENZELER 120G memiliki volume terendah, sekitar 4 unit per bulan, dengan

perubahan yang sangat kecil antarperiode. Secara keseluruhan, model LSTM berhasil menangkap pola historis yang stabil, sehingga prediksi dinilai sensitif dan representatif terhadap karakteristik data.

b. Evaluasi Akurasi Menggunakan MAPE

Gambar 4 menunjukkan nilai MAPE untuk masing-masing produk *frozen*. Berdasarkan grafik yang ditampilkan, seluruh produk memiliki nilai MAPE di bawah 10%, yang termasuk dalam kategori tingkat kesalahan rendah. Hal ini menunjukkan bahwa model peramalan yang digunakan memiliki tingkat akurasi yang sangat baik dalam memprediksi permintaan produk *frozen*. Dengan tingkat kesalahan yang relatif kecil, hasil peramalan dapat dijadikan dasar yang andal dalam proses perencanaan persediaan dan pengambilan keputusan operasional.




Gambar 4. Evaluasi MAPE untuk produk Frozen

Berdasarkan hasil evaluasi, nilai MAPE untuk masing-masing produk adalah NAGET SALAM 250G sebesar 16,02%, NAGET KENZELER 120G sebesar 16,11%, NAGET SO ECO 500G sebesar 9,89%, NAGET NGETOP 500G 9,89%, dan NAGET SALAM 500G sebesar 8,28%. Mengacu pada kriteria evaluasi peramalan, nilai MAPE kurang dari 10% dikategorikan sangat baik, nilai antara 10% hingga 20% dikategorikan baik, dan nilai di atas 20% dikategorikan cukup. Berdasarkan klasifikasi tersebut, produk dengan permintaan tinggi seperti NAGET SALAM 500G menunjukkan tingkat akurasi sangat baik, sedangkan produk dengan volume penjualan lebih rendah memiliki nilai MAPE yang sedikit lebih tinggi namun tetap berada dalam kategori baik. Selain itu, tidak terdapat produk dengan nilai MAPE di atas 20%, sehingga secara keseluruhan model peramalan dapat dinyatakan memiliki performa yang baik. Nilai MAPE yang relatif lebih tinggi pada produk dengan volume kecil merupakan hal yang wajar, karena pada data dengan skala permintaan rendah, selisih absolut yang kecil dapat menghasilkan persentase kesalahan yang tampak lebih besar secara proporsional.

c. Analisis Total Forecast Semua Produk


Gambar 5 menunjukkan total hasil peramalan seluruh produk *frozen* selama tiga bulan ke depan. Berdasarkan hasil prediksi, total permintaan pada bulan pertama sebesar 69,1 unit, bulan kedua sebesar 69,7 unit, dan bulan ketiga sebesar 68,2 unit. Nilai tersebut menunjukkan bahwa total permintaan agregat berada pada kisaran yang relatif stabil, yaitu antara 68 hingga 70 unit per bulan. Tidak terlihat adanya trend kenaikan maupun penurunan yang signifikan selama periode peramalan. Selain itu, variasi antarbulan sangat kecil, yaitu kurang dari 2%, yang mencerminkan tingkat kestabilan permintaan pada kategori *frozen*.



Gambar 5. Visualisasi Total Forecast untuk Produk Frozen

4.6 Evaluasi Hasil Peramalan Produk Sabun

Bagian ini menyajikan evaluasi hasil peramalan penjualan produk sabun berdasarkan model LSTM yang telah dikembangkan. Evaluasi dilakukan untuk menilai konsistensi pola prediksi jangka pendek, tingkat akurasi model menggunakan indikator MAPE, serta dinamika permintaan agregat selama tiga bulan ke depan. Dengan pendekatan ini, hasil peramalan tidak hanya dianalisis dari sisi kesalahan statistik, tetapi juga dari kemampuannya dalam merepresentasikan pola permintaan historis secara realistis dan aplikatif bagi perencanaan operasional.




Gambar 6. Visualisasi Trend Forcast untuk Produk Sabun

a. Analisis Trend Forecasting 3 Bulan

Berdasarkan visualisasi pada Gambar 6, prediksi penjualan produk sabun selama tiga bulan ke depan menunjukkan fluktuasi ringan namun relatif stabil. Tidak terdapat lonjakan maupun penurunan ekstrem, sehingga permintaan jangka pendek dapat dikatakan terkendali. Produk GIV 72 gr memiliki volume prediksi tertinggi, sekitar 43 unit pada bulan pertama, menurun pada bulan kedua, lalu meningkat kembali pada bulan ketiga, mencerminkan fluktuasi musiman ringan. LUX 70 gr dan GIV 76 gr menunjukkan pola serupa dengan penurunan sementara di periode kedua sebelum kembali meningkat, yang mengindikasikan pola siklikal jangka pendek. Sementara itu, Zen 80 gr dan Shinzui 65 gr yang memiliki volume lebih rendah memperlihatkan pergerakan yang stabil tanpa perubahan signifikan. Secara keseluruhan, model LSTM mampu merepresentasikan pola historis tanpa menghasilkan prediksi yang volatil, sehingga hasil *forecasting* dinilai stabil terhadap dinamika permintaan aktual.

b. Evaluasi Akurasi Menggunakan MAPE

Evaluasi akurasi dilakukan menggunakan indikator MAPE, yang mengukur rata-rata persentase kesalahan antara nilai aktual dan nilai prediksi. Berdasarkan hasil evaluasi yang diperlihatkan pada Gambar 7 menunjukkan bahwa seluruh produk sabun memiliki nilai MAPE di bawah 10%, yang termasuk dalam kategori sangat baik berdasarkan kriteria evaluasi peramalan. Nilai MAPE terendah terdapat pada produk Lifebuoy 60 gr, yang menunjukkan tingkat kesalahan prediksi yang sangat kecil. Hal ini mengindikasikan bahwa model mampu menangkap pola permintaan historis dengan tingkat akurasi yang tinggi pada seluruh kategori produk sabun.




Gambar 7. Evaluasi MAPE untuk produk Sabun

Sementara itu, nilai MAPE yang relatif lebih tinggi terdapat pada produk seperti Zen 80 gr dan Shinzui 85 gr, meskipun tetap berada dalam kategori sangat baik. Perbedaan ini dapat dipengaruhi oleh variasi volume penjualan serta sensitivitas persentase kesalahan pada produk dengan skala permintaan yang lebih kecil. Secara keseluruhan, hasil evaluasi menunjukkan bahwa model LSTM memiliki tingkat akurasi yang sangat baik dan layak digunakan sebagai dasar dalam proses perencanaan dan pengendalian persediaan produk sabun.

c. Total Forecasting Semua Produk

Analisis terhadap hasil visualisasi pada Gambar 8, total hasil peramalan seluruh produk sabun selama tiga bulan ke depan menunjukkan adanya dinamika permintaan agregat yang relatif moderat. Total prediksi permintaan pada bulan pertama sebesar 217,6 unit, mengalami penurunan menjadi 202,7 unit pada bulan kedua, kemudian meningkat kembali menjadi 208,5 unit pada bulan ketiga. Pola ini mengindikasikan adanya fluktuasi jangka pendek yang bersifat sementara, di mana terjadi koreksi permintaan pada periode kedua sebelum kembali mengalami pemulihan pada periode berikutnya.




Gambar 8. Visualisasi Total Forcast untuk Produk Sabun

Meskipun terjadi penurunan pada bulan kedua, perubahan tersebut tidak menunjukkan tren penurunan berkelanjutan, sehingga dapat dikategorikan sebagai variasi normal dalam siklus permintaan. Informasi ini penting dalam konteks perencanaan operasional karena memberikan gambaran mengenai kebutuhan penyesuaian persediaan pada periode tertentu. Hasil total forecasting ini selanjutnya dapat digunakan sebagai dasar dalam perhitungan kebijakan persediaan seperti *Safety Stock*, *Reorder Point*, dan *EOQ*, sehingga keputusan pengadaan dapat dilakukan secara lebih terukur dan berbasis data.

4.7 Evaluasi Hasil Peramalan Produk Susu

Bagian ini menyajikan evaluasi hasil peramalan penjualan produk susu berdasarkan model LSTM yang telah dikembangkan. Evaluasi dilakukan untuk menganalisis pola tren prediksi jangka pendek, mengukur tingkat akurasi menggunakan MAPE, serta menilai dinamika permintaan agregat selama tiga bulan ke depan. Analisis ini bertujuan untuk memastikan bahwa hasil forecast tidak hanya memiliki akurasi statistik yang tinggi, tetapi juga relevan secara operasional dalam mendukung perencanaan persediaan.




Gambar 9. Visualisasi Trend Forecast untuk Produk Susu

a. Analisis Trend Forecasting 3 Bulan

Berdasarkan visualisasi pada Gambar 9, lima varian produk susu menunjukkan tren meningkat selama tiga bulan ke depan. Model mampu menangkap pertumbuhan permintaan yang konsisten tanpa menghasilkan lonjakan ekstrem, sehingga mencerminkan dinamika permintaan yang ekspansif dalam jangka pendek. Produk SUSU ULTRAMILK COKLAT memiliki prediksi tertinggi, dari sekitar 103 unit pada bulan pertama menjadi 108–109 unit pada bulan berikutnya, menunjukkan peningkatan yang stabil. SUSU ULTRAMIMI FULL CREAM juga meningkat bertahap dari sekitar 82 unit menjadi hampir 90 unit pada bulan ketiga. SUSU ULTRAMILK STRAWBERRY naik ringan dari 59 menjadi 62 unit lalu relatif stabil, sementara SUSU ULTRAMILK FRESH MILK cenderung datar dengan sedikit fluktuasi sebelum kembali meningkat. SUSU ULTRAMIMI RASA VANILA memiliki volume terendah (21–23 unit), namun tetap menunjukkan kenaikan bertahap.

b. Evaluasi Akurasi Menggunakan MAPE

Evaluasi akurasi menggunakan indikator MAPE pada Gambar 10, menunjukkan bahwa seluruh produk susu memiliki tingkat kesalahan yang sangat rendah, berada pada kisaran 3%–5%. Produk SUSU ULTRAMILK FRESH MILK memiliki nilai MAPE sekitar 4,34%, diikuti SUSU ULTRAMILK COKLAT sebesar 4,79%, SUSU ULTRAMIMI FULL CREAM sebesar 4,3%, SUSU ULTRAMILK STRAWBERRY sebesar 4,89%, dan SUSU ULTRAMIMI RASA VANILA sebesar 4,73%.




Gambar 10. Evaluasi MAPE untuk produk Susu

Berdasarkan kriteria evaluasi peramalan, nilai MAPE di bawah 10% dikategorikan sangat baik. Dengan demikian, seluruh produk susu menunjukkan performa akurasi yang sangat tinggi. Rendahnya nilai error mengindikasikan bahwa model LSTM mampu mempelajari pola historis penjualan secara efektif serta memiliki kemampuan generalisasi yang baik terhadap data uji. Perbedaan kecil antarproduk dapat dipengaruhi oleh variasi fluktuasi historis dan tingkat stabilitas permintaan masing-masing varian, namun secara keseluruhan tidak terdapat indikasi *overfitting* maupun bias prediksi yang signifikan.

c. Analisis Total Forecast Semua Produk

Analisis terhadap total hasil peramalan seluruh produk susu selama tiga bulan menunjukkan adanya trend peningkatan permintaan agregat secara konsisten di tunjukan Gambar 11. Total prediksi penjualan sebesar 318,6 unit pada bulan pertama meningkat menjadi 335,6 unit pada bulan kedua dan kembali naik menjadi 337,3 unit

pada bulan ketiga. Kenaikan dari bulan pertama ke bulan ketiga sebesar 18,7 unit atau sekitar 5,9%, yang menunjukkan adanya kecenderungan peningkatan permintaan kategori susu dalam jangka pendek.



Gambar 11. Visualisasi Total Forecast untuk Produk Susu

Pola peningkatan bertahap ini mengindikasikan bahwa perusahaan perlu mengantisipasi kebutuhan persediaan yang lebih tinggi pada periode mendatang untuk menghindari risiko kekurangan stok. Tidak ditemukannya fluktuasi ekstrem menunjukkan bahwa pertumbuhan permintaan bersifat gradual dan dapat diprediksi secara relatif stabil. Oleh karena itu, hasil total forecast ini dapat dijadikan dasar dalam penyesuaian kebijakan pengadaan dan perencanaan kapasitas produksi.

4.8 Perhitungan Kebijakan Persediaan Berdasarkan Hasil Forecast

Berdasarkan hasil peramalan yang telah dievaluasi pada masing-masing kategori produk, kebijakan persediaan dihitung menggunakan pendekatan *Safety Stock*, *Reorder Point*, dan *EOQ*.

Table 2. Parameter Pengendalian Persediaan (*Safety Stock*, *Reorder Point*, dan *EOQ*)

Jenis Produk	Safety Stock	Reorder Point	EOQ
NAGET KENZELER 120G	0.93	5.25	2452.84
NAGET NGETOP 500G	1.6	10.83	2463.09
NAGET SALAM 250G	0.93	5.25	2445.27
NAGET SALAM 500G	4.85	38.99	2475.55
NAGET SO ECO 500G	2.9	19.08	2477.7
GIV 72 gr	5.51	46.69	2462.98
GIV 76 gr	3.86	32.36	2458.64
LUX 70 gr	3.35	28.3	2465.74
LUX 85 gr	2.48	17.57	2459.67
Lifebuoy 60 gr	4.26	35.31	2499.52
Lifebuoy 75 gr	2.52	24.7	2463.7
Shinzui 65 gr	2.13	14.49	2457.37
Shinzui 85 gr	1.52	9.52	2457.13
Zen 70 gr	2.13	17.49	2456.63
Zen 80 gr	1.52	9.52	2456.62
SUSU ULTRAMILK COKLAT	11.85	118.21	2452.4
SUSU ULTRAMILK FRESH MILK	6.27	60.58	2452.39
SUSU ULTRAMILK STRAWBERRY	7.12	68.07	2451.21
SUSU ULTRAMIMI FULL CREAM	9.93	95.84	2451.4
SUSU ULTRAMIMI RASA VANILA	2.85	25.21	2449.11


Perhitungan pada Table 2 bertujuan untuk menentukan jumlah persediaan pengaman, titik pemesanan ulang, serta kuantitas pemesanan optimal guna meminimalkan total biaya persediaan. Hasil agregasi menunjukkan bahwa kategori Susu memiliki nilai *Safety Stock* dan *Reorder Point* tertinggi dibandingkan kategori lainnya. Rata-rata *Safety Stock* sebesar 7,60 unit dan *Reorder Point* sebesar 73,58 unit mengindikasikan tingkat permintaan yang lebih besar serta variabilitas yang relatif tinggi. Nilai EOQ relatif stabil pada seluruh kategori, berada pada kisaran 2450–2460 unit. Stabilitas ini menunjukkan bahwa parameter biaya pemesanan dan penyimpanan cenderung konsisten, sehingga perbedaan kebijakan persediaan lebih dipengaruhi oleh karakteristik permintaan dibanding faktor biaya. Pada kategori *Frozen*, rata-rata *Reorder Point* sebesar 15,88 unit lebih rendah, namun standar deviasi sebesar 14,11 menunjukkan variasi yang cukup tinggi antar produk. Variabilitas ini lebih disebabkan oleh perbedaan volume permintaan masing-masing produk, bukan ketidakstabilan pola permintaan secara temporal. Dari sisi total prediksi tiga bulan ke depan, kategori Susu tetap mendominasi dengan kisaran 318,6–337,3 unit, jauh di atas kategori *Frozen* yang berada pada 68–70 unit. Oleh karena itu, pengendalian persediaan kategori Susu perlu menjadi prioritas, terutama dalam penentuan *Safety Stock* dan pemantauan *Reorder Point* guna menjaga tingkat layanan dan efisiensi biaya persediaan.

4.9 Keterbatasan Metodologis

Meskipun hasil penelitian menunjukkan performa model yang sangat baik, terdapat beberapa keterbatasan metodologis yang perlu diperhatikan. Penelitian ini belum melakukan perbandingan langsung dengan algoritma peramalan lain seperti ARIMA, *Random Forest*, atau *Prophet*, sehingga keunggulan relatif model LSTM belum diuji secara komparatif. Selain itu, variabel eksternal seperti promosi, hari besar, maupun faktor ekonomi makro belum dimasukkan sebagai fitur tambahan dalam model, sehingga pengaruh faktor eksogen terhadap permintaan belum terakomodasi secara eksplisit. Periode data yang digunakan juga relatif terbatas, sehingga pola musiman tahunan dan siklus jangka panjang mungkin belum sepenuhnya tertangkap oleh model. Keterbatasan ini menunjukkan bahwa meskipun model memiliki akurasi tinggi, masih terdapat ruang pengembangan untuk meningkatkan robustitas dan validitas eksternal hasil penelitian.

4.10 Arah Pengembangan Penelitian

Pengembangan penelitian selanjutnya dapat diarahkan pada beberapa aspek strategis untuk meningkatkan kualitas dan generalisasi model. Studi komparatif multi-model perlu dilakukan guna menguji signifikansi statistik perbedaan akurasi antar algoritma peramalan. Integrasi variabel eksogen ke dalam arsitektur LSTM juga berpotensi meningkatkan kemampuan model dalam menangkap dinamika permintaan yang dipengaruhi faktor eksternal.



Gambar 12. Implementasi berbasis web

Selain itu, pada Gambar 12 implementasi sistem berbasis web atau dashboard *real-time* dapat meningkatkan nilai praktis penelitian dalam konteks industri. Pengujian pada skala data yang lebih besar dan periode waktu yang lebih panjang juga diperlukan untuk memastikan stabilitas performa model serta meningkatkan daya generalisasi pada berbagai kategori produk.

5. KESIMPULAN

Penelitian ini menunjukkan bahwa model LSTM mampu menghasilkan tingkat akurasi yang baik dalam peramalan permintaan pada tiga kategori produk. Produk susu dan sabun mencapai kategori *highly accurate forecasting*, sementara produk *frozen* masih berada dalam kategori *acceptable forecasting*. Integrasi antara peramalan berbasis *deep learning* dan metode pengendalian persediaan memberikan kontribusi praktis dalam mendukung sistem pengambilan keputusan yang lebih presisi dan adaptif. Dengan pengembangan lanjutan pada aspek komparasi model dan integrasi variabel eksternal, pendekatan ini berpotensi dikembangkan menjadi sistem manajemen persediaan berbasis kecerdasan buatan yang lebih komprehensif. Kontribusi utama penelitian ini adalah integrasi metode LSTM dengan model pengendalian persediaan dalam satu kerangka analisis yang aplikatif. Penelitian ini memiliki keterbatasan pada penggunaan data historis yang terbatas serta belum mempertimbangkan variabel eksternal seperti promosi dan faktor musiman. Penelitian selanjutnya disarankan untuk mengintegrasikan variabel eksogen serta melakukan perbandingan dengan metode lain untuk meningkatkan akurasi model.

REFERENCES

- [1] R. Britania, A. Tjolleng, S. A. Putri, F. Teknik, and U. B. Nusantara, "Integrasi Model Inventori Eoq dan Time Series Forecasting Untuk Sistem Inventori Optimal," vol. 10, no. 1, pp. 78–93, 2024, doi: 10.30997/jvs.v10i1.13310.
- [2] D. I. Purnamasari, V. A. Permadi, A. Saepudin, and R. P. Agusdin, "Demand Forecasting For Improved Inventory Management in Small and Medium-Sized Businesses," vol. 12, no. 1, pp. 56–66, 2023, doi: <https://doi.org/10.23887/janapati.v12i1.57144>.
- [3] M. Munawar, U. E. Unggul, G. Firmansyah, U. E. Unggul, B. Tjahjono, and U. E. Unggul, "Comparative Analysis of Time Series Methods LSTM and ARIMA for Predicting Inventory Availability (Case Study : PT XYZ)," vol. 8, no. 1, pp. 1–19, 2025, doi: 10.33050/ccit.v18i1.3443.
- [4] M. A. Chaudhari, A. Phapale, P. Gagare, and T. Kardile, "sForecasting and Modelling of Food Demand Supply Chain using Machine Learning," vol. 13, no. 2, pp. 1–16, 2025.
- [5] W. Tang, "Applied Mathematics and Nonlinear Sciences Improvement of Inventory Management and Demand Forecasting by Big Data Analytics in Supply Chain," vol. 9, no. 1, pp. 1–15, 2024, doi: 10.2478/amns-2024-2213.
- [6] H. J. Wahedi, M. Heltoft, G. J. Christophersen, T. Severinsen, and S. Saha, "applied sciences Forecasting and Inventory Planning : An Empirical Investigation of Classical and Machine Learning Approaches for Svanehoj ' s Future Software Consolidation," vol. 13, no. 15, p. 8581, 2023, doi: <https://doi.org/10.3390/app13158581>.
- [7] D. S. Prastiya and R. S. Wahyuni, "Artificial Neural Network Model For Optimization of Forecasting Material Inventory," vol. 25, no. 2, pp. 173–188, 2024.
- [8] T. Lokhilmahful, R. Fitriana, A. Nur, and Y. Liang, "Optimizing Demand Forecasting Method with Support Vector Regression for Improved Inventory Planning," vol. 23, no. 2, pp. 149–166, 2024, doi: 10.25077/josi.v23.n2.p149-166.202.
- [9] A. F. Ridwan and M. Ahsan, "Penentuan Reorder Point dan Safety Stock pada Consumable Material Berdasarkan Peramalan Menggunakan Artificial Neural Network," vol. 6, no. 1, pp. 1–61, 2024, doi: <https://doi.org/10.37631/jri.v6i1.1220>.
- [10] N. Deivanayagampillai, T. Bhuvaneswari, and Y. Suppiah, "Intelligent inventory prediction : A machine learning framework using random forest for inventory forecasting," vol. 9, no. 4, pp. 1795–1807, 2025, doi: 10.55214/25768484.v9i4.6383.
- [11] S. A. Gresya, N. A. Rambe, M. G. Adelita, and F. F. Sitompul, "Penerapan Teknologi AI dan Machine Learning dalam Manajemen Talenta Conference Series Penerapan Teknologi AI dan Machine Learning dalam Manajemen Rantai Pasokan," vol. 7, no. 1, 2024, doi: 10.32734/ee.v7i1.2303.
- [12] E. S. D. Gulo, T. H. S. Hulu, S. M. Kakisina, and M. S. D. Mendrofa, "Analisis Peramalan Persediaan Barang Menggunakan Metode Moving Average Dan Exponential Smoothing Pada CV . Sanjaya Bangun Pratama," vol. 4, no. 3, pp. 1703–1716, 2024, doi: [doi: doi.org/jebma.v4n3.4788](https://doi.org/jebma.v4n3.4788) Analisis.
- [13] A. Merici and U. Saprudin, "Peramalan Persediaan Barang Menggunakan Metode Weighted Moving Average di CV . Multipaper Stationery," vol. 5, no. 2, pp. 1685–1694, 2024, doi: <https://doi.org/10.35870/jimik.v5i2.742>.
- [14] H. Hassyddiqy *et al.*, "Analisis Peramalan (Forecasting) Penjualan Dengan Metode (Autoregressive Integrated Moving Average) Pada Huebee Indonesia," vol. 2, no. 2, pp. 92–100, 2023, doi: <https://doi.org/10.47709/dsi.v2i2.2022>.
- [15] F. R. Kurniawan and R. Sutomo, "Forecasting Rice Inventory in Indonesia Using the ARIMA," vol. 1, no. 2, pp. 1–12, 2021, doi: 10.53748/jmis.v1i2.15.
- [16] E. Donneli *et al.*, "Big Data dan Peramalan Permintaan Rantai Pasokan dalam Pemasaran Digital UMKM," vol. 7, pp. 266–277, 2024.
- [17] S. Yunita, N. A. Mahesti, R. Max, B. Sihalohe, and R. Setyadi, "Forecasting Pada Rantai Pasok Pabrik Penggilingan Daging Menggunakan Metode Time Series," vol. 9, no. 3, pp. 761–769, 2022, doi: 10.30865/jurikom.v9i3.4221.
- [18] M. Kurniasih, W. Widayat, T. Informatika, F. Komunikasi, and U. M. Surakarta, "Sistem Informasi Manajemen Stok Berbasis Web Menggunakan Framework Laravel," vol. 5, no. 5, pp. 1457–1469, 2025, doi: <https://doi.org/10.52436/1.jpti.816>.
- [19] Anisah and Hadita, "Penerapan Metode Forecasting Dalam Menentukan Persediaan Kopi Susu Pada Usaha Mikro Kecil Menengah Dalam Hal Ini Sir Coffeehouse Bekasi," vol. 2, no. 1, pp. 97–107, 2024, doi: <https://doi.org/10.30640/jmcbus.v2i1.2070>.
- [20] S. Zaheer, N. Anjum, S. Hussain, A. D. Algarni, and J. Iqbal, "A Multi Parameter Forecasting for Stock Time Series Data Using LSTM and Deep Learning Model," vol. 11, no. 3, p. 590, 2023, doi: <https://doi.org/10.3390/math11030590>.
- [21] H. Imaduddin, L. A. Kusumaningtias, and F. Y. A., "Ingénierie des Systèmes d ' Information Application of LSTM and GloVe Word Embedding for Hate Speech Detection in Indonesian Twitter Data," vol. 28, no. 4, pp. 1107–1112, 2023, doi: <https://doi.org/10.18280/isi.280430>.

