

Analisis Prediksi Permintaan Produk FMCG menggunakan Model LSTM dan DES Untuk Optimalisasi Operasional Gudang Distribusi

Tanti Cahya Herdiyani¹, Taswanda Taryo², Kahfi Heryandi Suradiradja³, Zafira Salsabilah⁴

^{1,2,3}Magister Teknik Informatika, Universitas Pamulang, htanticahya@gmail.com

⁴Independent Researcher, zafirasalsabilah21@gmail.com

Keywords:

Deep Learning,
DES,
Fast-Moving Consumer Goods,
LSTM,
Prediction

ABSTRACT

The Fast-Moving Consumer Goods (FMCG) sector is characterized by rapid product turnover and short shelf lives, requiring effective inventory management. Companies such as PT Macrocentra Niagaboga face challenges in maintaining stock availability. Although the inventory system has been integrated, stock verification is still conducted manually, requiring adaptive management to minimize the risk of overstock and stockout. Therefore, this study aims to develop a demand forecasting model using the Long Short-Term Memory (LSTM) algorithm integrated with Discrete-Event Simulation (DES) to optimize inventory management. The study utilized historical shipment data from May 2025 to January 2026. Preprocessing included data cleansing, date validation, and aggregation into daily and weekly data. Forecasting results were subsequently used as inputs for the DES simulations to determine optimal inventory policies. The results demonstrated that weekly LSTM aggregation was more accurate and stable than daily aggregation, as evidenced by a reduction in WAPE from 49.9% to 16.94% for high-demand products. Furthermore, integration with DES reduced stock levels by more than 30% using a safety stock ratio of 0.7 without compromising service levels. Finally, the proposed model was implemented in a web-based dashboard serving as a decision support system for monitoring forecasting and inventory policy recommendations.

Kata Kunci:

Deep Learning,
DES,
Fast-Moving Consumer Goods,
LSTM,
Prediksi

ABSTRAK

Sektor *Fast-Moving Consumer Goods* (FMCG) memiliki karakteristik perputaran produk yang cepat dan umur simpan yang pendek, sehingga membutuhkan pengelolaan persediaan. Perusahaan seperti PT Macrocentra Niagaboga menghadapi tantangan dalam menjaga ketersediaan stok. Meskipun sistem persediaan telah terintegrasi, proses verifikasi stok masih dilakukan manual sehingga diperlukan pengelolaan yang lebih adaptif untuk meminimalkan risiko *overstock* dan *stockout*. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model prediksi permintaan menggunakan algoritma *Long Short-Term Memory* (LSTM) yang diintegrasikan dengan *Discrete-Event Simulation* (DES) untuk mengoptimalkan pengelolaan persediaan. Penelitian ini menggunakan data historis pengiriman periode Mei 2025 hingga Januari 2026. Tahap *preprocessing* meliputi *cleansing data*, validasi tanggal, serta agregasi data harian dan mingguan. Hasil *forecasting* kemudian digunakan sebagai *input* pada simulasi DES untuk menentukan kebijakan persediaan yang optimal. Hasil penelitian menunjukkan bahwa agregasi mingguan pada model LSTM memberikan hasil yang lebih akurat dan stabil dibandingkan agregasi harian, ditunjukkan dengan penurunan nilai WAPE dari 49,9% menjadi 16,94% pada produk kategori *high demand*. Selain itu, integrasi dengan DES mampu menurunkan tingkat persediaan lebih dari 30% menggunakan *safety stock ratio* sebesar 0,7 tanpa menurunkan tingkat layanan. Penelitian ini juga diimplementasikan dalam bentuk *dashboard* berbasis web sebagai *decision support system* untuk *monitoring forecasting* dan rekomendasi kebijakan persediaan.

Korespondensi Penulis:

Tanti Cahya Herdiyani,
Universitas Pamulang, Jl. Puspitek, Buaran, Kec. Pamulang,
Kota Tangerang Selatan, Banten 15310
Telepon : +6285887745185
Email: htanticahya@gmail.com

Submitted : 17-05-2026; Accepted : 14-07-2026;
Published : 27-07-2026

Copyright (c) 2026 The Author (s) This article is distributed
under a Creative Commons Attribution-ShareAlike 4.0
International License (CC BY-SA 4.0)

1. PENDAHULUAN

Sektor *Fast-Moving Consumer Goods* (FMCG) merupakan sektor yang melayani permintaan pelanggan dengan tingkat perputaran produk yang tinggi dan pola permintaan yang dinamis, sehingga membutuhkan pengelolaan persediaan yang efisien [1]. Tingginya permintaan produk FMCG di Indonesia mendorong perusahaan distribusi untuk menjaga ketersediaan stok di gudang. Namun, karakteristik produk FMCG yang memiliki umur simpan relatif pendek menyebabkan perusahaan rentan mengalami *overstock* maupun *stockout* apabila perencanaan persediaan tidak dilakukan secara optimal [2].

PT Macrocentra Niagaboga sebagai perusahaan FMCG yang mendistribusikan produk makanan dan minuman dari Cimory Group memiliki kebutuhan untuk menjaga keseimbangan ketersediaan stok. Meskipun sistem pencatatan stok telah terintegrasi, proses pengecekan ketersediaan produk di gudang masih melibatkan verifikasi secara langsung oleh tim operasional untuk memastikan kesesuaian kondisi stok aktual. Dinamika permintaan yang tinggi menyebabkan perusahaan perlu melakukan pengelolaan persediaan yang lebih adaptif agar ketersediaan produk tetap terjaga, sekaligus meminimalkan potensi *overstock* maupun *stockout* serta mendukung optimalisasi tingkat pelayanan persediaan. Untuk mengatasi permasalahan tersebut, diperlukan pendekatan prediktif yang mampu menganalisis pola historis permintaan produk untuk memperkirakan kebutuhan stok di masa mendatang [3]. Dalam beberapa tahun terakhir, metode *deep learning* banyak digunakan pada permasalahan *forecasting* deret waktu karena mampu menangkap pola non linier dan dependensi jangka panjang pada data historis [4]. Salah satu metode yang banyak digunakan adalah *Long Short-Term Memory* (LSTM), yang dirancang untuk mempelajari pola temporal melalui mekanisme memori internal sehingga mampu menghasilkan prediksi yang lebih stabil pada data permintaan yang fluktuatif [5].

Berbagai penelitian yang menggunakan LSTM menunjukkan hasil yang baik dalam prediksi permintaan dan pengelolaan stok, seperti prediksi kebutuhan stok obat dengan akurasi di atas 70% serta prediksi stok *raw material* dengan MAPE sebesar 10,79% [6], [7]. Penelitian dengan metode *Gated Recurrent Unit* (GRU) juga menunjukkan performa yang baik pada prediksi permintaan produk dengan nilai RMSE sebesar 247,3952 [8]. Sementara itu, metode *Random Forest*, Regresi Linear, serta metode konvensional seperti *Exponential Smoothing* masih memiliki keterbatasan dalam menangkap pola temporal pada data deret waktu [9], [10].

Meskipun demikian, sebagian besar penelitian sebelumnya [8], [9], [10] masih terbatas pada *forecasting* dan belum mengintegrasikan hasil prediksi ke dalam simulasi sistem persediaan. Selain itu, penelitian *forecasting* FMCG umumnya masih menggunakan pendekatan agregasi permintaan secara umum tanpa mempertimbangkan perbedaan karakteristik pola *demand* antar produk, sehingga hasil *forecasting* berpotensi kurang adaptif ketika diterapkan pada kondisi operasional nyata [6], [11]. Kondisi ini diperparah oleh terbatasnya evaluasi terhadap ketahanan (*robustness*) kebijakan pada kondisi *demand* yang berubah-ubah, sehingga performa sistem pada lingkungan manajemen persediaan yang dinamis belum dapat dianalisis secara menyeluruh [12].

Untuk mengatasi keterbatasan tersebut, penelitian ini menerapkan mekanisme *adaptive fallback* yang secara otomatis menentukan skala agregasi waktu (harian dan mingguan) terbaik berdasarkan nilai *Weighted Absolute Percentage Error* (WAPE), di mana model dengan nilai WAPE terendah dipilih sebagai model terbaik untuk setiap SKU. Penggunaan WAPE dinilai lebih representatif dalam evaluasi *forecasting* permintaan karena mempertimbangkan proporsi *error* terhadap total *demand* sehingga lebih sesuai untuk data dengan skala permintaan yang bervariasi dan *intermittent demand* [13]. Selain itu, evaluasi metrik *forecasting* juga dilakukan menggunakan *Mean Absolute Error* (MAE), *Weighted Absolute Percentage Error* (WAPE), dan Bias untuk mengukur tingkat akurasi prediksi serta kecenderungan *overforecast* maupun *underforecast* pada setiap SKU [14], [15], [16].


Hasil *forecasting* kemudian diintegrasikan dengan *Discrete-Event Simulation* (DES) untuk merepresentasikan dinamika sistem persediaan dan mengevaluasi kebijakan persediaan pada kondisi operasional yang lebih realistis. Pendekatan DES dipilih karena mampu memodelkan aliran proses berbasis *event* diskrit seperti permintaan dan proses pengisian kembali stok (*replenishment*), serta telah banyak digunakan bersama metode *deep learning* maupun *neural network* dalam optimasi sistem persediaan dan produksi [17], [18].

Pada penelitian ini, DES digunakan untuk mensimulasikan kebijakan persediaan berbasis *continuous review* (s, S) dalam kondisi operasional yang dinamis, di mana pemesanan kembali dilakukan ketika level persediaan mencapai titik *reorder point* (s) hingga kembali ke level maksimum persediaan (S). Kebijakan *continuous review* dipilih karena mampu merepresentasikan kondisi permintaan stok yang bersifat *stochastic* dan fluktuatif, sehingga lebih sesuai untuk evaluasi performa sistem persediaan pada lingkungan operasional nyata [19]. Pada proses simulasi juga mempertimbangkan faktor *lead time*, *stockout*, *lost sales*, serta ketidakpastian permintaan menggunakan pendekatan *Monte Carlo* untuk merepresentasikan variasi kondisi operasional secara lebih realistis melalui proses *random sampling* dan evaluasi berulang terhadap performa sistem persediaan [12].

Penelitian ini memberikan kontribusi utama berupa: (1) pengembangan model *forecasting* LSTM berbasis mekanisme *adaptive fallback* (*daily-weekly*) yang sesuai dengan karakteristik *demand* FMCG; (2) integrasi hasil *forecasting* dengan DES untuk mengevaluasi dan mengoptimalkan kebijakan persediaan secara dinamis; (3) evaluasi *robustness* melalui pendekatan *Monte Carlo* untuk menjamin ketahanan sistem terhadap ketidakpastian; serta (4) implementasi *Decision Support System* (DSS) dalam bentuk *dashboard* berbasis web untuk *monitoring* hasil prediksi dan memberikan rekomendasi kebijakan persediaan secara sistematis.

2. METODE PENELITIAN

Penelitian ini dilakukan melalui beberapa tahapan utama, yaitu persiapan dataset, pemodelan LSTM, simulasi DES, dan evaluasi kinerja sistem persediaan. Alur penelitian ditunjukkan pada Gambar 1.



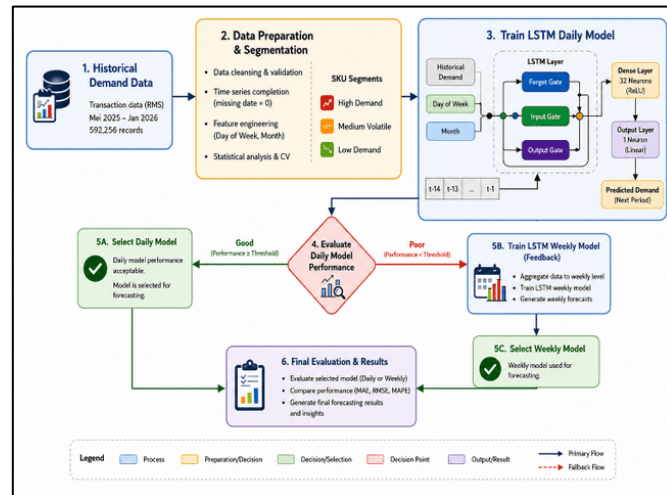
Gambar 1. Alur penelitian.

2.1 Persiapan Dataset

Dataset diperoleh dari aplikasi *Routing Management System* (RMS) PT Macrosentra Niagaboga periode Mei 2025 hingga Januari 2026 dengan atribut utama berupa *Delivery Date*, Kode Produk (SKU), *Product Name*, dan *Quantity*. Pemilihan atribut tersebut didasarkan pada kebutuhan pembentukan data deret waktu (*time series*) untuk proses *forecasting* permintaan. Atribut *Delivery Date* digunakan untuk menunjukkan waktu terjadinya pengiriman produk sehingga data dapat diurutkan berdasarkan waktu dan digunakan untuk membentuk pola historis permintaan. Atribut Kode Produk (SKU) berfungsi sebagai identitas unik setiap produk sehingga proses analisis dan peramalan dapat dilakukan secara spesifik pada masing-masing produk. Atribut *Product Name* digunakan sebagai informasi deskriptif untuk mendukung interpretasi hasil analisis. Dan atribut *Quantity* merepresentasikan jumlah permintaan aktual yang menjadi variabel target dalam proses peramalan. Dengan demikian, keempat atribut tersebut mampu menyediakan informasi yang relevan untuk membangun model prediksi permintaan berdasarkan pola historis pengiriman produk. Selanjutnya dilakukan tahapan *preprocessing* yang meliputi *data cleansing*, validasi data, agregasi *demand* harian, serta pembentukan fitur waktu seperti *day of week*, *week*, dan *month*. Selain itu, dilakukan segmentasi SKU berdasarkan karakteristik demand menjadi *high*, *volatile*, dan *intermittent* menggunakan nilai rata-rata *demand* dan *coefficient of variation* (CV).

2.2 Perancangan Model LSTM

Model *Long Short-Term Memory* (LSTM) merupakan metode *deep learning* yang efektif untuk mempelajari pola temporal dan dependensi jangka panjang pada data deret waktu [20]. Arsitektur model LSTM yang digunakan pada penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Perancangan model LSTM.

Model menerima *input sequence* berupa data historis *demand* selama 14 hari sebelumnya yang dilengkapi dengan fitur waktu. Data tersebut kemudian diproses pada lapisan LSTM yang memiliki mekanisme memori internal melalui *forget gate*, *input gate*, dan *output gate* untuk mempelajari pola temporal serta dependensi jangka panjang pada data deret waktu [14]. *Output* dari lapisan LSTM selanjutnya diteruskan ke *dense layer* dengan 32 neuron dan fungsi aktivasi ReLU, kemudian menghasilkan nilai prediksi *demand* pada periode berikutnya melalui *output layer* dengan satu *neuron linear*.

Model dibangun menggunakan TensorFlow Keras dan dilatih menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,001, *batch size* 32, dan 100 *epoch* menggunakan fungsi *loss Mean Absolute Error* (MAE). Dataset dibagi menggunakan pendekatan *time-based split* dengan proporsi 80% data latih dan 20% data uji. Proses pembagian dataset ini bertujuan untuk mengevaluasi kinerja model secara realistis serta menghindari *overfitting* [21].

Untuk meningkatkan adaptivitas terhadap karakteristik *demand* FMCG yang fluktuatif dan *intermittent*, diterapkan mekanisme *adaptive fallback* melalui pendekatan *dual-stage modeling*. Sistem pertama-tama mengevaluasi performa model LSTM dengan agregasi harian. Apabila nilai WAPE melampaui ambang batas tertentu (*threshold*), sistem secara otomatis melakukan agregasi ulang data ke skala mingguan dan melatih kembali (*retraining*) model agar pola permintaan dapat dipelajari secara lebih optimal. *Output* dari model terpilih selanjutnya digunakan sebagai *input* dalam proses simulasi kebijakan persediaan menggunakan DES.

2.3 Evaluasi Prediksi Model LSTM

Evaluasi model dilakukan untuk menilai tingkat akurasi hasil prediksi yang dihasilkan oleh model LSTM [14]. Evaluasi dilakukan menggunakan tiga metrik, yaitu *Mean Absolute Error* (MAE), *Weighted Absolute Percentage Error* (WAPE), dan *Mean Forecast Error* (MFE).

MAE digunakan untuk mengukur nilai rata-rata kesalahan absolut antara nilai aktual dan nilai prediksi [22], seperti ditunjukkan pada Persamaan 1.

$$MAE = \frac{1}{m} \sum_{i=1}^m |(X_i - Y_i)| \quad (1)$$

Dalam hal ini, X_i merepresentasikan nilai aktual dan Y_i merupakan nilai prediksi untuk setiap data ke- i , sementara m menunjukkan jumlah total data yang digunakan dalam analisis.

WAPE digunakan karena lebih stabil dibandingkan MAPE pada data *demand* yang mengandung nilai nol atau sangat kecil [15]. WAPE dihitung menggunakan Persamaan 2.

$$WAPE = \frac{\sum_{t=1}^m |e_t|}{\sum_{t=1}^m y_t} \times 100 \quad (2)$$

Dalam hal ini, e_t menunjukkan selisih antara nilai aktual dan nilai prediksi pada waktu ke- t , sedangkan y_t merupakan nilai aktual pada periode tersebut.

Interpretasi tingkat akurasi prediksi menggunakan pendekatan interpretasi MAPE menurut skala Lewis, yang diadaptasi untuk membaca nilai WAPE karena keduanya sama-sama merepresentasikan kesalahan prediksi dalam bentuk persentase. Berdasarkan interpretasi tersebut, klasifikasi tingkat akurasi dapat diketahui pada Tabel 1 [23].

Tabel 1. Interpretasi nilai WAPE.

Nilai WAPE	Kategori
$\leq 10\%$	<i>Highly Accurate</i>
11% – 20%	<i>Good</i>
21% – 50%	<i>Reasonable</i>
$\geq 51\%$	<i>Inaccurate</i>

MFE atau Bias digunakan untuk mengidentifikasi kecenderungan model dalam melakukan *overforecast* maupun *underforecast* [10]. Nilai MFE dihitung menggunakan Persamaan 3.

$$MFE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t) \quad (3)$$

Dalam hal ini, Y_t merepresentasikan nilai aktual pada periode ke- t , $\hat{Y}_t$ merupakan nilai hasil prediksi, dan n menunjukkan jumlah total observasi yang dianalisis.

2.4 Perancangan Simulasi Model DES dan Kebijakan Persediaan

Hasil *forecasting* dari model LSTM diintegrasikan ke dalam simulasi DES untuk menguji kebijakan persediaan *continuous review* (s, S) [24]. Dalam model ini, pesanan akan dipicu saat posisi persediaan menyentuh titik pemesanan kembali (*reorder point* atau s) dengan jumlah pemesanan variabel hingga mencapai batas maksimum (S) [25], sebagaimana Persamaan 4 dan Persamaan 5.

$$ROP = (AU \times L) + SS \quad (4)$$

$$SS = z \times \sigma \times L \quad (5)$$

Dalam hal ini, ROP merepresentasikan titik pemesanan kembali (*reorder point*), L menunjukkan waktu tunggu (*lead time*), dan SS adalah persediaan pengaman (*safety stock*). Sementara itu, z menyatakan nilai faktor tingkat pelayanan (*service level*) dan σ menggambarkan nilai fluktuasi *demand*.

Dalam implementasinya, penelitian ini menggunakan pendekatan *protection period* ($L + R$) untuk menyesuaikan proses simulasi DES dan *review period system*, sehingga parameter *reorder point* dihitung menggunakan rata-rata *demand* dan standar deviasi *demand* hasil *forecasting* LSTM, sebagaimana ditunjukkan pada Persamaan 6–9.

$$P = L + R \quad (6)$$

$$SS = Z\sigma\sqrt{P} \quad (7)$$

$$s = \mu P + SS \quad (8)$$

$$S = s + \mu R \quad (9)$$

Dalam hal ini, P menyatakan periode perlindungan (*protection period*) yang diperoleh dari penjumlahan *lead time* pemesanan (L) dan periode peninjauan persediaan (R). Sementara itu, komponen persediaan pengaman (*safety stock* atau SS) dihitung berdasarkan nilai *service level* dari distribusi normal (Z) serta standar deviasi (σ) dan rata-rata (μ) dari *demand* hasil *forecasting*. Terakhir, s menunjukkan titik pemesanan kembali (*reorder point* atau batas minimum persediaan), sedangkan S merupakan target maksimum persediaan setelah dilakukan pemulihan (*replenishment*).

Simulasi diinisialisasi dengan stok awal sebesar S untuk menghindari *bias* pada kondisi awal sistem, kemudian memproses *input* permintaan LSTM yang telah ditambahkan *random noise* distribusi normal sebagai representasi ketidakpastian. Secara diskrit, sistem mengevaluasi kecukupan stok, mencatat *stockout* sebagai *lost sales*, dan mensimulasikan penerimaan barang sesuai durasi *lead time* untuk menghasilkan metrik performa sistem yang realistis.

2.5 Simulasi dan Evaluasi Simulasi Model DES

Evaluasi dilakukan melalui simulasi *baseline*, *Monte Carlo*, dan *safety stock tuning* untuk menentukan parameter persediaan yang optimal dan *robust* terhadap variasi permintaan [17]. Setiap skenario dievaluasi menggunakan metrik *fill rate*, *stockout days*, dan *average on-hand inventory*.

3. HASIL DAN PEMBAHASAN

3.1 Karakteristik Dataset

Dataset penelitian diperoleh dari aplikasi *Routing Management System* (RMS) PT. Macrosentra Niagaboga periode Mei 2025 hingga Januari 2026. Setelah tahap *preprocessing*, data dibentuk menjadi deret waktu permintaan harian (*daily demand*) berdasarkan SKU produk. Dataset mentah tersebut mencakup keseluruhan 262 SKU produk

aktif. Setelah tahap *preprocessing*, data dibentuk menjadi deret waktu permintaan harian (*daily demand*) berdasarkan SKU produk. Selanjutnya dilakukan segmentasi SKU menggunakan nilai rata-rata permintaan dan *coefficient of variation* (CV) untuk mengelompokkan produk berdasarkan pola *demand*. Dari hasil segmentasi tersebut, dipilih tiga SKU representatif yang mewakili tiga kategori pola *demand* dalam industri FMCG, yaitu *high demand* (KM-053), *volatile demand* (S-063), dan *intermittent demand* (KM-069). Pemilihan ini berfungsi sebagai sampel untuk mengevaluasi kinerja model *forecasting* dan simulasi persediaan pada variasi pola permintaan yang umum ditemukan dalam dataset tanpa harus melakukan analisis secara terpisah terhadap seluruh SKU. Karakteristik detail dari ketiga SKU terpilih tersebut disajikan pada Tabel 2.

Tabel 2. Karakteristik dataset produk.

SKU	Kategori	Total Demand	Rata-rata Harian	Std Dev	CV	Hari Non-Zero
KM-053	High	187.470	723,82	539,91	0,75	259
S-063	Volatile	3.383	36,38	67,38	1,85	93
KM-069	Intermittent	496	2,02	8,35	4,13	245

Hasil analisis menunjukkan bahwa SKU KM-053 memiliki pola permintaan tinggi dengan tingkat fluktuasi yang relatif stabil, ditunjukkan oleh nilai *coefficient of variation* (CV) sebesar 0,75. Sementara itu, SKU S-063 memiliki karakteristik *volatile demand* dengan nilai CV sebesar 1,85, yang menunjukkan adanya variasi permintaan yang cukup tinggi. Pada SKU KM-069, nilai CV mencapai 4,13 dengan jumlah hari *non-zero* yang sangat sedikit, sehingga menunjukkan pola *intermittent demand* yang didominasi oleh nilai nol.

Perbedaan karakteristik tersebut menunjukkan bahwa pola permintaan antarproduk bersifat heterogen, sehingga pendekatan pemodelan perlu mempertimbangkan karakteristik masing-masing SKU. Kondisi ini menjadi dasar penerapan mekanisme *fallback* antara model harian (*daily*) dan mingguan (*weekly*) untuk memperoleh performa prediksi yang lebih adaptif terhadap pola demand FMCG.

3.2 Evaluasi Kinerja Model Prediksi LSTM


Pada tahap awal, dilakukan pelatihan model LSTM menggunakan data harian (*daily*) untuk mengevaluasi kemampuan model dalam mempelajari pola permintaan masing-masing SKU. Hasil evaluasi model harian dirangkum pada Tabel 3.

Tabel 3. Evaluasi prediksi model harian LSTM.


SKU	Qty Act	Qty Pred	MAE	WAPE (%)	Bias (%)	Ket
KM-053	31.365	29.853,94	347,82	49,90	-4,82	Reasonable
S-063	746,00	361,58	73,79	118,70	-51,53	Inaccurate
KM-069	1,00	15,95	0,40	1.695,46	1.495,46	Inaccurate

Hasil evaluasi menunjukkan bahwa performa model harian dipengaruhi oleh karakteristik *demand* masing-masing produk. Pada SKU KM-053 dengan kategori *high demand*, model masih mampu mengikuti pola permintaan dengan nilai WAPE sebesar 49,90%. Sebaliknya, SKU S-063 dengan karakteristik *medium volatile* menghasilkan performa yang kurang stabil dengan WAPE sebesar 118,70% akibat tingginya fluktuasi permintaan. Pada SKU KM-069 dengan karakteristik *intermittent demand*, pendekatan harian menghasilkan performa yang sangat buruk karena dominasi nilai nol menyebabkan model sulit mempelajari pola permintaan secara optimal.

Visualisasi *training loss* dan *validation loss* menunjukkan bahwa model pada SKU KM-053 memiliki pola konvergensi yang lebih stabil dibandingkan SKU S-063 dan KM-069, yang masih menunjukkan keterbatasan generalisasi pada data *volatile* dan *intermittent*.



Gambar 3. Visualisasi model harian produk *high demand*: (a) grafik *train loss* dan *val loss*; (b) perbandingan nilai aktual dan prediksi.



Gambar 4. Visualisasi model harian produk *medium volatile*: (a) grafik *train loss* dan *val loss*; (b) perbandingan nilai aktual dan prediksi.

Untuk mengatasi fluktuasi dan *sparsity* pada data harian, dilakukan agregasi permintaan ke tingkat mingguan (*weekly*). Pendekatan ini bertujuan untuk mereduksi *noise* sehingga pola permintaan menjadi lebih stabil dan lebih mudah dipelajari oleh model. Hasil evaluasi model mingguan ditunjukkan pada Tabel 4.


Tabel 4. Evaluasi prediksi model mingguan LSTM

SKU	<i>Qty Act</i>	<i>Qty Pred</i>	MAE	WAPE (%)	Bias (%)	Ket
KM-053	167.644	169.144,97	739,35	16,94	11,23	<i>Good</i>
S-063	2.988	3.303,11	104,68	30,54	14,63	<i>Reasonable</i>
KM-069	446	0,32	0,002	0,00	0,00	<i>Highly Accurate</i>


Hasil evaluasi menunjukkan bahwa pendekatan mingguan secara konsisten menghasilkan performa yang lebih baik dibandingkan pendekatan harian pada seluruh SKU. Pada SKU KM-053, nilai WAPE berhasil diturunkan secara signifikan dari 49,90% menjadi 16,94%. Penurunan *error* ini menunjukkan bahwa agregasi mingguan mampu mereduksi fluktuasi harian sehingga pola permintaan menjadi lebih stabil. Pada SKU S-063, performa model juga meningkat secara signifikan dengan penurunan WAPE dari 118,70% menjadi 30,54%. Pendekatan mingguan berhasil mengurangi volatilitas permintaan sehingga model mampu menghasilkan prediksi yang lebih konsisten dibandingkan model harian. Sementara itu, pada SKU KM-069 dengan karakteristik *intermittent demand*, pendekatan mingguan menghasilkan performa yang lebih stabil dibandingkan model harian.

Agregasi mingguan membantu mengurangi tingkat *sparsity* sehingga model dapat merepresentasikan pola dasar permintaan dengan lebih baik, meskipun masih memiliki keterbatasan dalam menangkap lonjakan permintaan yang tidak teratur. Nilai WAPE sebesar 0,00% pada SKU ini dipengaruhi oleh karakteristik *demand* yang sangat rendah dan relatif stabil pada periode agregasi mingguan, sehingga selisih antara nilai aktual dan hasil prediksi menjadi sangat kecil. Oleh karena itu, interpretasi nilai WAPE pada SKU *intermittent demand* perlu dilakukan secara hati-hati karena *error* persentase dapat menjadi sangat kecil ketika volume *demand* rendah.

Secara umum, kurva *training loss* dan *validation loss* pada model mingguan menunjukkan pola konvergensi yang lebih stabil dibandingkan pendekatan harian. Hal ini mengindikasikan bahwa agregasi mingguan membantu meningkatkan kemampuan generalisasi model terhadap data validasi.



Gambar 5. Visualisasi model mingguan produk *high demand*: (a) grafik *train loss* dan *val loss*; (b) perbandingan nilai aktual dan prediksi.



Gambar 6. Visualisasi model mingguan produk *medium volatile*: (a) grafik *train loss* dan *val loss*; (b) perbandingan nilai aktual dan prediksi.

Perbandingan performa model harian dan mingguan ditunjukkan pada Tabel 5.

Tabel 5. Perbandingan kinerja performa model harian dan mingguan.

SKU	WAPE <i>Daily</i> (%)	WAPE <i>Weekly</i> (%)	Model Terbaik
KM-053	49,90	16,94	<i>Weekly</i>
S-063	118,70	30,54	<i>Weekly</i>
KM-069	1.495,46	0,00	<i>Weekly</i>

Hasil perbandingan menunjukkan bahwa pendekatan mingguan secara konsisten memberikan performa yang lebih baik pada seluruh SKU. Penurunan WAPE yang signifikan mengonfirmasi bahwa agregasi waktu mereduksi *noise* dan *sparsity* secara efektif. Pada skala mingguan, terjadi efek kompensasi *error*, di mana fluktuasi acak harian saling meniadakan saat diakumulasi. Hal ini menghasilkan pola tren yang lebih bersih, sehingga mekanisme memori LSTM dapat menangkap dependensi jangka panjang secara lebih optimal dibandingkan pada data harian yang volatil.

3.3 Simulasi DES dan Optimalisasi

Hasil *forecasting* terbaik selanjutnya digunakan sebagai *input* pada simulasi *Discrete-Event Simulation* (DES) untuk mengevaluasi kebijakan persediaan berbasis (s, S). Simulasi dilakukan dengan mempertimbangkan *lead time*, *lost sales*, dan mekanisme *reorder* ketika stok berada di bawah batas minimum (s) hingga mencapai target persediaan (S). Hasil simulasi *baseline* ditunjukkan pada Tabel 6.

Tabel 6. Simulasi pengujian *baseline* DES.

SKU	Total Demand	Total Terpenuhi	Fill Rate	Stockout Days	Avg On Hand	s	S
KM-053	21.443	21.443	100%	0	9.887,25	11.177	16.460
S-063	1.266	1.266	100%	0	668	799	1.116
KM-069	1	1	100%	0	1,75	2	2

Hasil simulasi menunjukkan bahwa kebijakan *baseline* mampu mempertahankan *fill rate* sebesar 100% tanpa *stockout*, namun dengan rata-rata persediaan yang relatif tinggi, khususnya pada SKU KM-053 dengan *average on-hand inventory* mencapai 9.887 unit. Untuk meningkatkan efisiensi persediaan, dilakukan *safety stock tuning* dengan beberapa skenario *safety factor*. Hasil pengujian menunjukkan bahwa *safety factor* 0,7 masih mampu mempertahankan *fill rate* sebesar 100% tanpa meningkatkan *stockout days*, sekaligus menurunkan rata-rata persediaan secara signifikan. Pada SKU KM-053, *average inventory* berhasil diturunkan lebih dari 35%, sedangkan pada SKU S-063 turun dari 668 unit menjadi 441 unit. Temuan ini menunjukkan bahwa optimasi *safety stock* mampu meningkatkan efisiensi persediaan tanpa menurunkan tingkat pelayanan (*service level*). Perbandingan kondisi awal sistem dan hasil simulasi ditunjukkan pada Tabel 7.

Tabel 7. Perbandingan kondisi awal sistem dengan hasil simulasi.

SKU	Kondisi	Fill Rate	Stockout Days	Avg On Hand
KM-053	Baseline	100%	0	9.887,25
KM-053	Optimal	100%	0	6.108,13
S-063	Baseline	100%	0	668,00
S-063	Optimal	100%	0	441,14
KM-069	Baseline	100%	0	1,75
KM-069	Optimal	100%	0	0,75

3.4 Evaluasi Simulasi Model DES dan Implikasi pada Operasional


Hasil simulasi Model DES yang dilakukan dengan *Monte Carlo* menunjukkan bahwa skenario *low safety* dengan *safety factor* 0,8 masih mampu mempertahankan *fill rate* sebesar 100% tanpa meningkatkan *stockout days* pada seluruh SKU. Selain itu, skenario tersebut menghasilkan rata-rata persediaan yang lebih rendah dibandingkan kebijakan *baseline*, khususnya pada SKU KM-053 dan S-063. Hasil ini menunjukkan bahwa sistem masih memiliki ruang untuk menurunkan level *safety stock* tanpa menurunkan tingkat pelayanan yang ditunjukkan pada Tabel 8.

Tabel 8. Hasil simulasi dengan ketidakpastian permintaan.

SKU	Skenario	Safety Factor	Fill Rate (Mean)	Fill Rate (p05)	Stockout Days (p95)	Avg On Hand
KM-053	Baseline	1,0	100%	100%	0	9.954,88
KM-053	Low Safety	0,8	100%	100%	0	7.553,38
KM-053	Optimal	0,7	100%	100%	0	6.288,91
S-063	Baseline	1,0	100%	100%	0	708,33
S-063	Low Safety	0,8	100%	100%	0	528,98
S-063	Optimal	0,7	100%	100%	0	451,54
KM-069	Baseline	1,0	100%	100%	0	1,76
KM-069	Low Safety	0,8	100%	100%	0	1,76
KM-069	Optimal	0,7	100%	100%	0	0,76

Berdasarkan hasil tersebut, dilakukan proses *safety factor tuning* lebih lanjut untuk menentukan parameter (*s*, *S*) yang paling optimal. Pengujian dilakukan menggunakan beberapa nilai *safety factor* hingga diperoleh nilai optimal sebesar 0,7 untuk seluruh SKU. Hasil optimasi menunjukkan bahwa kebijakan tersebut tetap mampu mempertahankan *fill rate* sebesar 100% dengan *stockout days* sebesar 0, namun menghasilkan rata-rata persediaan yang lebih rendah dibandingkan kondisi *baseline* maupun skenario *low safety*. Pada SKU KM-053, rata-rata persediaan berhasil diturunkan menjadi 6.288 unit atau lebih dari 35% dibandingkan *baseline*, sedangkan pada SKU S-063 turun menjadi 451 unit. Sementara itu, SKU KM-069 tetap mempertahankan *fill rate* sebesar 100% dengan rata-rata persediaan sebesar 0,76 unit atau dibulatkan menjadi 1 unit. Hasil tersebut menunjukkan bahwa *safety factor* 0,7 merupakan parameter yang paling optimal untuk meningkatkan efisiensi persediaan tanpa menurunkan nilai pelayanan.

Hasil tersebut menunjukkan integrasi LSTM dan DES mampu menghasilkan prediksi *demand* yang adaptif serta kebijakan persediaan yang *robust* terhadap fluktuasi permintaan FMCG tanpa meningkatkan risiko *stockout*. Untuk mendukung implementasi operasional, hasil *forecasting* dan simulasi persediaan selanjutnya diimplementasikan pada *dashboard* berbasis web *decision support system* yang menampilkan hasil *forecasting*, performa simulasi, dan rekomendasi parameter (*s*, *S*) secara terintegrasi, seperti ditunjukkan pada Gambar 7.

Gambar 7. Implementasi *dashboard* prediksi permintaan produk.

Pada implementasi *dashboard* untuk SKU KM-053, sistem mampu mempertahankan *fill rate* sebesar 100% tanpa *stockout* dengan total *forecasting* permintaan mencapai 21.443 unit. *Dashboard* menampilkan parameter kebijakan (s , S), kondisi stok saat ini, serta rekomendasi *reorder* secara terintegrasi. Berdasarkan hasil simulasi, stok saat ini masih berada di atas batas minimum persediaan sehingga sistem belum merekomendasikan pemesanan ulang. Implementasi *dashboard* membantu *monitoring* persediaan dan mendukung pengambilan keputusan persediaan secara lebih cepat dan berbasis data.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem *forecasting* dan optimasi persediaan berbasis integrasi *Long Short-Term Memory* (LSTM) dan *Discrete-Event Simulation* (DES) pada manajemen persediaan produk FMCG. Hasil penelitian menunjukkan bahwa pendekatan mingguan (*weekly*) menghasilkan performa *forecasting* yang lebih baik dibandingkan pendekatan harian (*daily*), khususnya pada kondisi permintaan yang *volatile* dan *intermittent*. Pada SKU KM-053, nilai WAPE berhasil diturunkan dari 49,90% menjadi 16,94%, sedangkan pada SKU S-063 pendekatan mingguan menghasilkan prediksi yang lebih stabil dibandingkan model harian.

Hasil simulasi DES menunjukkan bahwa kebijakan persediaan berbasis (s , S) mampu mempertahankan *fill rate* sebesar 100% tanpa *stockout*. Melalui proses *safety stock tuning*, diperoleh *safety factor* optimal sebesar 0,7 yang berhasil menurunkan rata-rata persediaan lebih dari 30% dibandingkan kondisi *baseline* tanpa menurunkan tingkat pelayanan (*service level*). Selain itu, simulasi *Monte Carlo* menunjukkan bahwa kebijakan yang dihasilkan tetap *robust* terhadap ketidakpastian permintaan. Sistem juga dikembangkan dalam bentuk *dashboard* berbasis web sebagai *decision support system* (DSS) untuk *monitoring forecasting* dan rekomendasi persediaan secara terintegrasi.

Penelitian selanjutnya dapat mempertimbangkan penggunaan variabel tambahan dalam model *forecasting*, seperti faktor musiman (*seasonality*), program promosi, maupun variabel eksternal lainnya untuk meningkatkan akurasi prediksi pada model harian maupun mingguan.

REFERENSI

- [1] L. Isyriyah, I. Baihaqi, and F. E. Purwiantono, "Prediksi Loyalitas Pelanggan Pada Fast Moving Consumer Goods Menggunakan Klasifikasi Metode C4.5," *SMATIKA JURNAL*, vol. 13, no. 02, pp. 369–380, Jan. 2024, doi: 10.32664/smatika.v13i02.1115.
- [2] R. W. Kristanto and R. R. Padmakusumah, "PENGARUH IMPLEMENTASI LEAN DAN WAREHOUSE MANAGEMENT SYSTEM TERHADAP KINERJA LOGISTIK PADA INDUSTRI FMCG PT. XYZ," *Jurnal Ilmiah Manajemen, Ekonomi, & Akuntansi (MEA)*, vol. 9, no. 1, pp. 547–566, 2025.
- [3] D. Irawan, E. Apriliyanto, and D. Mardiaty, "Prediksi Pengiriman Teh Kemuning Di Ngargoyoso Menggunakan Algoritma Monte Carlo (Studi Kasus Pt. Rumpun Sari Kemuning)," *Juti Unisi*, vol. 7, no. 1, pp. 43–47, 2023.
- [4] D. Putra Romadhon and R. Eka Putra, "Penerapan Metode Deep Learning Menggunakan Algoritma CNN based Recommendation pada Aplikasi E-Commerce Gols (Studi Kasus : PT. Cipta Giri Sentosa)," *Journal of Informatics and Computer Science*, vol. 05, 2024.

- [5] H. Abbasimehr and M. K. Nahari, "Improving demand forecasting with LSTM by taking into account the seasonality of data," *Journal of Applied Research on Industrial Engineering*, vol. 7, no. 2, pp. 177–189, 2020, doi: <https://doi.org/10.22105/jarie.2020.232594.1168>.
- [6] S. Salahuddin, M. Khadafi, and O. Yusianti, "Sistem Prediksi Kebutuhan Stock Obat Menggunakan Metode Long Short Term Memory (LSTM) Time Series Berbasis Deep Learning," in *Prosiding Seminar Nasional Politeknik Negeri Lhokseumawe*, 2025, pp. 26–33.
- [7] P. Anjarwati and P. Widyaningsih, "Raw Material Stock Prediction Using the Long Short-Term Memory Algorithm (Case Study: Mizan and Sunan Grilled Bread Producers)," *Journal of Artificial Intelligence and Software Engineering*, vol. 5, no. 3, pp. 1296–1308, 2025, doi: 10.30811/jaise.v5i3.7199.
- [8] R. A. Saputra, Y. Azhar, and V. Rahmayanti, "Prediksi Permintaan Kargo pada Cargo Service Center Tangerang City Menggunakan Metode Gated Recurrent Unit," *REPOSITOR*, vol. 2, no. 8, pp. 1113–1122, 2020.
- [9] A. Ichwani, L. Wahyu, A. Saputro, G. Putra Pradana, and J. Maulindar, "Implementasi Algoritma Random Forest untuk Prediksi Permintaan dan Optimasi Stok pada Sistem Manajemen Inventori Layanan Pengiriman Makanan," *Seminar Nasional Teknologi Informasi dan Bisnis (SENATIB)*, p. 2025, 2025.
- [10] L. A. Anbar and W. Wahyudin, "Peramalan permintaan tas laptop menggunakan model time series," *Journal Industrial Servicess*, vol. 7, no. 2, p. 285, Apr. 2022, doi: 10.36055/jiss.v7i2.14326.
- [11] J. K. Franco, N. M. Guevara, P. Castaneda, J. Mansilla-Lopez, and A. D. Garcia-Nunez, "A Machine Learning-Based Stock Forecasting Method for Inventory Optimization in Micro and Small Enterprises," *Engineering, Technology & Applied Science Research*, vol. 16, no. 1, pp. 32081–32088, 2026.
- [12] M. Mazzi, L. Aboueljineane, and M. Lebbar, "Monte Carlo Simulation and Genetic Algorithm for Optimizing Hospital Medicine Inventory Management under Uncertainty," *Procedia Comput. Sci.*, vol. 277, pp. 3093–3102, 2026.
- [13] D. Dornela Goulart, R. de Carvalho, M. Almeida Henriques, and B. Kawany Gonçalves Nunes Carvalho, "Predictive models for inventory optimization: a machine learning application for demand forecasting at a construction supplies distributor," *Future Business Journal*, vol. 12, no. 1, p. 92, 2026.
- [14] D. Susilo, A. Chusyairi, M. Ikhwan Saputra, U. Siber Asia, J. R. Harsono, and P. Minggu Jakarta Selatan, "Sistematis : Jurnal Ilmiah Sistem Informasi Prediksi Penjualan Untuk Optimasi Stock Produk Menggunakan Algoritma Long Short Term Memory," 2025, doi: 10.69533.
- [15] E. Caro and J. Juan, "Probabilistic analysis of electricity load forecasting errors," *Electric Power Systems Research*, vol. 255, Jun. 2026, doi: 10.1016/j.epsr.2026.112807.
- [16] A. González and V. Parada, "An Adaptive Model Selection Framework for Demand Forecasting under Horizon-Induced Degradation to Support Business Strategy and Operations," *arXiv preprint arXiv:2602.13939*, 2026.
- [17] R. Skapinyecz, "Recent Trends in the Optimization of Logistics Systems Through Discrete-Event Simulation and Deep Learning," Sep. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/a18090573.
- [18] P. Raska, Z. Ulrych, J. Baloun, M. Malaga, and L. Lenc, "USING ADAPTIVE NEURAL NETWORKS FOR OPTIMISING DISCRETE EVENT SIMULATION," *International Journal of Simulation Modelling*, vol. 23, no. 2, pp. 227–238, Jun. 2024, doi: 10.2507/IJSIMM23-2-678.
- [19] E. Sherzer and Y. Barron, "Supervised Learning for the (s, S) Inventory Model with General Interarrival Demands and General Lead Times," *arXiv preprint arXiv:2601.12900*, 2026.
- [20] Y. Li and Z. Wei, "Regional Logistics Demand Prediction: A Long Short-Term Memory Network Method," *Sustainability (Switzerland)*, vol. 14, no. 20, Oct. 2022, doi: 10.3390/su142013478.
- [21] J. Anggara, F. R. Ramadhan, A. F. Syofian, A. A. Panjaitan, and R. F. Fithra, "Pengembangan Sistem Prediksi Harga dan Rekomendasi Mobil Bekas Berbasis Machine Learning," *Journal of Technology and Informatics (JoTI)*, vol. 7, no. 1, pp. 11–23, Apr. 2025, doi: 10.37802/joti.v7i1.987.
- [22] R. Zaqi Megantara, P. Iryanto Faot, R. Haba Ito, K. Felicia Annabel, and O. Karnalim, "Pemanfaatan Machine Learning dalam Prediksi Rating: Studi Kasus pada Data Abstrak Publikasi Ilmiah," *Journal of Technology and Informatics (JoTI)*, vol. 7, no. 1, pp. 62–75, Apr. 2025, doi: 10.37802/joti.v7i1.999.
- [23] I. R. Siregar, A. Nugraha, K. A. Notodiputro, Y. Angraini, and L. N. A. Mualifah, "The comparison of long short-term memory and bidirectional long short-term memory for forecasting coal price," *BAREKENG: JURNAL ILMU MATEMATIKA DAN TERAPAN Учёбумену: Universitas Pattimura*, vol. 19, no. 1, pp. 245–258, 2025.
- [24] E. Bottani and G. Casella, "Discrete-event simulation in logistics and supply chain management: a scientometric perspective," *Prod. Manuf. Res.*, vol. 12, no. 1, 2024, doi: 10.1080/21693277.2024.2415038.
- [25] M. Kholil, I. Almahdy, A. Fortinina, and A. Suparno, "Implementation of continuous review system method, periodic review system method and min-max method for cheese powder inventory (Case study: PT. Mayora Indah TBK)," *International Journal of Advanced Technology in Mechanical, Mechatronics and Materials*, vol. 1, no. 2, pp. 45–49, 2020.