Terbit *online* pada laman web jurnal : http://inomet.ft.unand.ac.id

INoMeT: Jurnal Inovasi Rekayasa Mekanikal dan Termal

| ISSN (Online) 3025-2598 |

Artikel Penelitian

PENGEMBANGAN SISTEM PREDIKSI PERMINTAAN UNTUK *REORDER POINT* BERBASIS MACHINE LEARNING

Asmuliardi Muluk [a], Andre Nugraha Akbar[a]

[a]Departement Teknik Industri, Fakultas Teknik, Universitas Andalas, Kampus Limau Manis, Padang, 25163, Indonesia

INFORMASI ARTIKEL

Sejarah Artikel:
Diterima Redaksi: 23 Juni 2025
Revisi Akhir: 28 Juni 2025
Diterbitkan *Online*: 30 Juni 2025

KATA KUNCI

Machine learning
Overstock
Reorder Point
Safety Stock
Stockout

KORESPONDENSI

E-mail: asmuliardi@eng.unand.ac.id

A B S T R A C T

Inventory management is a critical aspect of retail operations, particularly in preventing overstock and stockout, which can affect customer satisfaction and potential sales. Fluctuating consumer demand presents a challenge in accurately determining the *Reorder Point* (ROP) and *Safety Stock* (SS). This study aims to develop a machine learning-based demand forecasting model to support inventory control decisions at XYZ Mart. The dataset consists of historical sales data from October 2023 to September 2024. The algorithms applied include Decision Tree, Random Forest, and XGBoost, evaluated using MAPE, RMSE, and TimeSeriesSplit cross-validation. Results show that XGBoost achieved the best performance with a MAPE of 0.0955% and an RMSE of 0.0418. Features such as Lag_1_days, Rolling_Mean_3, and product KODE contributed significantly to the model's accuracy. The best-performing model was integrated into the ROP and SS calculation system and implemented through a Streamlit-based interactive dashboard. The system provides automated ordering recommendations based on forecasts, improving inventory control accuracy and operational efficiency in the retail environment.

1. PENDAHULUAN

Manajemen persediaan merupakan salah satu elemen paling vital dalam rantai pasok sebuah perusahaan, terutama dalam sektor ritel yang memiliki dinamika permintaan tinggi dan terus berubah. Pengelolaan stok yang tidak tepat dapat menyebabkan dua risiko utama, yaitu stockout dan overstock [1]. Stockout dapat mengakibatkan hilangnya peluang penjualan, penurunan tingkat kepuasan pelanggan, bahkan kerugian loyalitas jangka panjang. Sebaliknya, overstock dapat membebani perusahaan dengan biaya penyimpanan yang tinggi, meningkatnya risiko produk kadaluarsa, hingga pemborosan sumber daya [2]. Oleh karena itu, diperlukan strategi pengendalian persediaan yang tepat guna menjaga keseimbangan antara ketersediaan produk dan kebutuhan aktual pelanggan.

Tabel 1.Rekapitulasi Penjualan Produk AQUA BTL 600ML XYZ Mart

Tanggal	Nama Barang	QTY	Stock
01/08/2024	AQUA BTL 600ML	6	234
02/08/2024	AQUA BTL 600ML	6	228
03/08/2024	AQUA BTL 600ML	12	216
04/08/2024	AQUA BTL 600ML	12	204
05/08/2024	AQUA BTL 600ML	12	192
06/08/2024	AQUA BTL 600ML	6	186
07/08/2024	AQUA BTL 600ML	12	174
08/08/2024	AQUA BTL 600ML	12	162
09/08/2024	AQUA BTL 600ML	6	156
11/08/2024	AQUA BTL 600ML	18	138
13/08/2024	AQUA BTL 600ML	6	132
15/08/2024	AQUA BTL 600ML	6	126
16/08/2024	AQUA BTL 600ML	6	120
17/08/2024	AQUA BTL 600ML	6	114
18/08/2024	AQUA BTL 600ML	12	102
19/08/2024	AQUA BTL 600ML	12	90
20/08/2024	AQUA BTL 600ML	6	84

https://doi.org/10.25077/inomet.3.1.79-84.2025

Attribution-NonCommercial 4.0 International. Some rights reserved

21/08/2024	AQUA BTL 600ML	6	78
22/08/2024	AQUA BTL 600ML	6	72
23/08/2024	AQUA BTL 600ML	12	60
24/08/2024	AQUA BTL 600ML	6	54
25/08/2024	AQUA BTL 600ML	24	30
26/08/2024	AQUA BTL 600ML	6	24
27/08/2024	AQUA BTL 600ML	12	12
29/08/2024	AQUA BTL 600ML	6	234
30/08/2024	AQUA BTL 600ML	6	228
31/08/2024	AQUA BTL 600ML	12	216

Permasalahan tersebut juga tampak dalam kondisi aktual pada XYZ Mart. Berdasarkan data historis penjualan dan stok produk AQUA BTL 600ML pada Tabel 1, diketahui bahwa pada periode 01–29 Agustus 2024 terjadi penurunan stok secara bertahap akibat transaksi penjualan harian. Pada tanggal 27 Agustus 2024, stok menyentuh titik kritis yaitu hanya tersisa 12 unit, sebelum akhirnya diisi ulang kembali pada tanggal 29 Agustus 2024. Kondisi ini mengindikasikan potensi stockout jika pemesanan ulang tidak dilakukan lebih awal. Ketiadaan sistem yang mampu memberikan peringatan dini atas kondisi stok minimum membuat proses pengadaan menjadi reaktif, bukan prediktif.

Masalah ini bukan hanya terjadi di level mikro. Menurut laporan industri global, kerugian akibat overstock dan stockout diperkirakan mencapai USD 1,75 triliun atau setara dengan Rp28.820 triliun per tahun, atau sekitar 8,3% dari total penjualan ritel dunia [3]. Angka ini menunjukkan betapa pentingnya pengelolaan persediaan yang akurat dan responsif untuk menjaga kelangsungan profitabilitas dan pelayanan pelanggan.

Salah satu pendekatan dalam pengendalian stok yang umum digunakan adalah penetapan *Reorder Point* (ROP) dan *Safety Stock* (SS). ROP berfungsi sebagai batas ambang jumlah minimum stok yang memicu proses pemesanan ulang, sementara SS digunakan sebagai cadangan untuk mengantisipasi ketidakpastian permintaan dan lead time [4]. Namun, tantangan muncul ketika permintaan konsumen bersifat fluktuatif dan tidak dapat diprediksi secara konsisten. Hal ini menjadikan pendekatan perhitungan manual atau statis tidak lagi memadai dalam menghadapi kompleksitas dan dinamika pasar saat ini.

Selama beberapa dekade, metode-metode konvensional seperti moving average, exponential smoothing, dan ARIMA telah banyak digunakan untuk peramalan permintaan. Metode ini memiliki keunggulan dalam hal kemudahan implementasi dan pemahaman, namun memiliki keterbatasan dalam mengenali pola non-linier, efek musiman tidak tetap, atau hubungan kompleks antar variabel [4]. Ketika data bersifat sangat fluktuatif atau memiliki banyak faktor yang memengaruhi, metode statistik klasik sering kali memberikan prediksi yang kurang akurat. Studi oleh Tulli [5] dan Ayyıldız [6] mengonfirmasi bahwa akurasi metode tradisional cenderung menurun dalam konteks permintaan yang tidak stasioner atau melibatkan banyak dimensi data..

Di tengah tantangan tersebut, pendekatan machine learning (ML) muncul sebagai alternatif yang menjanjikan. ML memungkinkan komputer untuk mempelajari pola dari data historis dan melakukan prediksi secara adaptif terhadap data baru. Algoritma seperti Decision Tree, Random Forest, dan XGBoost telah terbukti efektif dalam berbagai studi prediksi permintaan di sektor ritel dan manufaktur [7]. Penelitian oleh Hutagalung et al. [8]dan Ganguly dan Mukherjee [9] menunjukkan bahwa penggunaan XGBoost mampu menghasilkan prediksi dengan akurasi tinggi, bahkan pada data yang kompleks dan jumlah variabel yang besar. Kelebihan lain dari machine learning adalah kemampuannya untuk melakukan feature selection, yaitu memilih fitur yang paling relevan terhadap target prediksi, sehingga meningkatkan efisiensi dan akurasi model secara keseluruhan [10].

Namun, berdasarkan tinjauan literatur yang ada, sebagian besar penelitian hanya berfokus pada pembangunan model prediksi, tanpa mengintegrasikan hasil prediksi tersebut ke dalam sistem pengambilan keputusan secara langsung, seperti sistem perhitungan ROP dan SS. Di sinilah letak gap penelitian ini. Penelitian ini tidak hanya membangun model prediksi berbasis ML, tetapi juga mengintegrasikannya ke dalam sistem

 https://doi.org/10.25077/inomet.3.1.79-84.2025

operasional berbasis aplikasi yang dapat digunakan langsung oleh pengguna toko ritel tanpa keahlian teknis. Dengan pendekatan ini, sistem diharapkan dapat memberikan saran pemesanan ulang secara otomatis, berdasarkan prediksi permintaan yang dihasilkan dari data historis dan parameter operasional toko.

Studi kasus dilakukan pada XYZ Mart, sebuah toko ritel dengan jumlah SKU yang cukup banyak dan tingkat permintaan yang tidak selalu konsisten. Berdasarkan pengamatan awal dan data historis yang dihimpun, toko ini menghadapi tantangan dalam menjaga ketersediaan stok secara optimal. Sistem pemantauan yang masih bersifat manual, dan ketergantungan pada intuisi dalam melakukan restock, kerap menyebabkan keterlambatan pemesanan atau penumpukan stok. Oleh karena itu, pengembangan sistem prediksi permintaan yang otomatis dan adaptif menjadi kebutuhan yang mendesak untuk meningkatkan efisiensi operasional dan pengambilan keputusan yang berbasis data.

Penelitian ini bertujuan untuk mengembangkan model prediksi permintaan menggunakan algoritma machine learning yang relevan dan andal, seperti Decision Tree, Random Forest, dan XGBoost. Model yang dibangun dievaluasi menggunakan metrik akurasi seperti MAPE dan RMSE, serta validasi silang menggunakan TimeSeriesSplit. Model terbaik kemudian diintegrasikan ke dalam sistem perhitungan ROP dan SS yang dirancang untuk menyesuaikan secara dinamis dengan kondisi permintaan. Sistem ini selanjutnya diimplementasikan dalam bentuk aplikasi berbasis Streamlit agar dapat digunakan langsung oleh pengguna non-teknis di lingkungan toko.

Pertanyaan utama yang ingin dijawab dalam penelitian ini adalah: Apakah sistem prediksi permintaan berbasis machine learning yang dikembangkan dapat meningkatkan efektivitas perhitungan *Reorder Point* dan *Safety Stock* serta mengurangi risiko overstock dan stockout dibandingkan dengan metode manual yang digunakan sebelumnya? Penelitian ini diharapkan dapat memberikan kontribusi nyata dalam menggabungkan teknologi prediktif modern dengan kebutuhan praktis dalam manajemen persediaan ritel, serta menjadi rujukan bagi pengembangan sistem serupa di sektor lain yang memiliki karakteristik permintaan yang dinamis.

2. METODOLOGI

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksploratif-prediktif yang bertujuan membangun model prediksi permintaan untuk mendukung pengendalian persediaan melalui perhitungan *Reorder Point* (ROP) dan *Safety Stock* (SS). Objek penelitian adalah data transaksi penjualan harian produk di XYZ Mart selama periode Oktober 2023 hingga September 2024. Data tersebut diperoleh dari sistem internal toko dalam bentuk digital dan mencakup atribut seperti tanggal transaksi, kode produk, nama produk, kategori, supplier, satuan, dan jumlah barang terjual (quantity).

Pengolahan data dilakukan menggunakan perangkat lunak Python dengan bantuan pustaka seperti *Pandas, NumPy, Scikit-learn, XGBoost,* dan *Streamlit* [11]. Proses dimulai dengan pembersihan data (data cleaning), yang mencakup penghapusan duplikasi, penanganan nilai kosong, dan identifikasi outlier menggunakan pendekatan IQR (interquartile range) [12]. Selanjutnya dilakukan konversi tipe data, termasuk transformasi kolom tanggal menjadi format datetime untuk memungkinkan ekstraksi fitur waktu seperti bulan dan hari. Data kategori seperti supplier dan kategori barang diubah menjadi numerik menggunakan teknik label encoding.

Tahap feature engineering dilakukan untuk meningkatkan akurasi model, dengan menghasilkan fitur baru seperti Lag_1_days, Lag_2_days, dan Rolling_Mean_3, yang merepresentasikan pola permintaan harian maupun tren jangka pendek. Setelah itu, data dibagi menjadi dua bagian: data pelatihan (train) dan data pengujian (test), dengan proporsi 80:20 dan menggunakan metode TimeSeriesSplit untuk menjaga urutan kronologis data.

Pemodelan dilakukan dengan menerapkan tiga algoritma supervised learning, yaitu Decision Tree Regressor, Random Forest Regressor, dan XGBoost Regressor. Masing-masing model dievaluasi berdasarkan metrik MAPE (Mean Absolute Percentage Error) dan RMSE (Root Mean Squared Error) untuk mengukur tingkat kesalahan prediksi [13]. Selain itu, dilakukan validasi silang berbasis time series untuk memastikan kemampuan generalisasi model terhadap data baru. Hasil tuning hyperparameter dilakukan menggunakan GridSearchCV khusus untuk model XGBoost, dengan parameter seperti learning_rate, max_depth, dan n_estimators [14].

Model terbaik berdasarkan nilai MAPE dan RMSE terkecil kemudian diintegrasikan ke dalam sistem penghitungan ROP dan SS. Perhitungan SS menggunakan rumus, $SS = Z \times \sigma \times \sqrt{LT}$, di mana Z adalah z-score untuk tingkat servis yang ditentukan, σ adalah deviasi standar permintaan, dan LT adalah lead time. ROP dihitung dengan formula: ROP = (Demand × Lead Time) + SS, di mana permintaan berasal dari hasil prediksi model [15]. Sistem ini selanjutnya diimplementasikan dalam bentuk dashboard interaktif berbasis Streamlit [16], yang memungkinkan pengguna non-teknis untuk memasukkan parameter dan mendapatkan output berupa grafik permintaan, nilai ROP dan SS, serta saran pemesanan ulang.

Analisis dilakukan dengan membandingkan performa masing-masing model serta mengevaluasi efektivitas sistem melalui validasi terhadap kondisi stok aktual. Validasi dilakukan dengan membandingkan tanggal terjadinya stockout aktual dan tanggal rekomendasi pemesanan yang dihasilkan sistem. Validasi ini bertujuan untuk melihat apakah sistem mampu memberikan peringatan dini secara akurat, serta mengevaluasi dampak potensial implementasi sistem terhadap pengurangan risiko stockout dan overstock di lingkungan toko ritel.

3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan membangun sistem prediksi permintaan berbasis machine learning untuk mendukung perhitungan Reorder Point (ROP) dan Safety Stock (SS) dalam pengendalian persediaan ritel. Tiga model regresi digunakan: Decision Tree, Random Forest, dan XGBoost. Hasil evaluasi awal pada data baseline dan fitur terpilih ditampilkan pada Tabel 2 berikut.

Tabel 2. Hasil Evaluasi Nilai MAPE dan RMSE Baseline dan Top Feature

Model	*Baseline*		*Top Feature*	
	MAPE	**RMSE**	**MAPE**	**RMSE**
XGBoost	0,116%	0,0478	0,109%	0,0441
Random Forest	0,133%	0,0727	0,121%	0,0670
Decision Tree	0,142%	0,0899	0,116%	0,0800

XGBoost menunjukkan performa terbaik dan dipilih untuk proses tuning parameter. Hasil tuning menggunakan GridSearchCV dengan TimeSeriesSplit sebagai validasi silang menghasilkan konfigurasi terbaik: learning_rate=0.1, max_depth=7, dan n_estimators=200. Hasil tuning ditampilkan pada Gambar 1 berikut.

```
Tuning XGBoost hyperparameters...
Fitting 5 folds for each of 27 candidates, totalling 135 fits

===== TUNED MODEL RESULTS =====
Best Parameters: {'learning_rate': 0.1, 'max_depth': 7, 'n_estimators': 200}
Train MAPE: 0.0270%, Train RMSE: 0.0072
Test MAPE: 0.0955%, Test RMSE: 0.0418
CV MAPE: 0.1824% (±0.1018%)
```

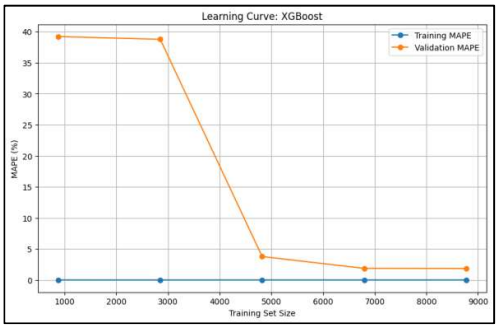
Gambar 1. Hasil Validasi dan Tuning Model XGBoost

Hasil tuning menunjukkan peningkatan performa model secara signifikan, dengan Train MAPE sebesar 0,0270% dan Test MAPE 0,0955%, serta RMSE pada data uji sebesar 0,0418. Validasi silang menghasilkan CV MAPE sebesar 0,1824% (±0,1018%), menunjukkan model memiliki stabilitas prediksi yang baik.

Lebih lanjut, untuk mengevaluasi kecenderungan overfitting, digunakan grafik learning curve yang dapat diliat pada Gambar 2. Hasil evaluasi pada

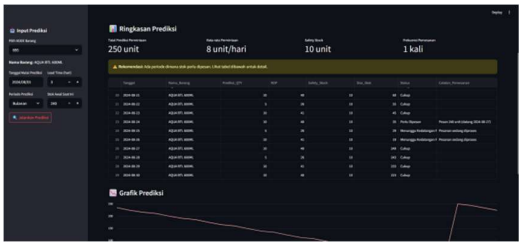
 https://doi.org/10.25077/inomet.3.1.79-84.2025

proses validasi dilihat bahwa MAPE pada data pelatihan tetap rendah, sementara kurva validasi menurun seiring bertambahnya data pelatihan, menunjukkan model memiliki kemampuan generalisasi yang baik.



Gambar 2. Grafik Learning Curve Model XGBoost

Model terbaik diintegrasikan ke dalam sistem aplikasi prediksi berbasis web menggunakan framework Streamlit. Gambar 3 memperlihatkan tampilan antarmuka sistem. Pengguna dapat memilih produk, tanggal prediksi, jumlah stok saat ini, dan lead time. Output sistem meliputi prediksi permintaan harian, ROP, SS, status stok, serta rekomendasi pemesanan ulang.



Gambar 3. Tampilan Hasil Integrasi Sistem Prediksi Permintaan & ROP Toko Retail

Contoh pada Gambar 3 menunjukkan hasil prediksi untuk produk AQUA BTL 600ML dengan rata-rata permintaan 8 unit/hari dan SS sebesar 10 unit. Sistem merekomendasikan pemesanan ulang pada tanggal 24 Agustus karena stok diprediksi akan berada di bawah ROP dalam waktu dekat.

Dibandingkan dengan metode manual, sistem ini menunjukkan peningkatan akurasi dalam pengendalian stok dan waktu pemesanan. Kemampuan sistem dalam membaca pola permintaan dan memperkirakan kebutuhan mendatang menjadikan pendekatan berbasis machine learning lebih unggul daripada metode konvensional. Temuan ini sejalan dengan penelitian oleh Liu & Vakharia (2024) dan Ganguly & Mukherjee (2024), yang juga mencatat peningkatan akurasi prediksi dalam manajemen persediaan ritel melalui model XGBoost.

Selain itu, implementasi sistem dalam bentuk dashboard memperluas akses pengguna non-teknis untuk mengambil keputusan berbasis data. Hal ini mendukung efisiensi operasional dan mendorong otomatisasi pengendalian stok.

4. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem prediksi permintaan berbasis machine learning yang terintegrasi dengan perhitungan Reorder Point (ROP) dan Safety Stock (SS) untuk mendukung manajemen persediaan pada sektor ritel. Dengan menggunakan data historis penjualan, model prediktif dilatih menggunakan tiga algoritma utama, yaitu Decision Tree, Random Forest, dan XGBoost. Evaluasi performa menunjukkan bahwa XGBoost memberikan hasil terbaik dengan akurasi tinggi berdasarkan nilai MAPE dan RMSE terendah.

Model kemudian diimplementasikan dalam bentuk dashboard interaktif yang mampu memberikan rekomendasi pemesanan ulang secara otomatis berdasarkan prediksi permintaan. Sistem ini secara efektif membantu meminimalkan risiko terjadinya overstock dan stockout dengan memberikan peringatan lebih awal saat stok berada di bawah nilai ROP.

Hasil penelitian menunjukkan bahwa pendekatan machine learning tidak hanya mampu meningkatkan keakuratan dalam pengendalian persediaan, tetapi juga mendukung pengambilan keputusan yang lebih efisien dan berbasis data. Sistem yang dikembangkan terbukti layak untuk diimplementasikan dalam operasional harian ritel karena dapat merespons dinamika permintaan dengan lebih adaptif.

DAFTAR PUSTAKA

[1] S. Bahagia, Sistem Inventory. Bandung: ITB, 2006.

[2] N. L. Rachmawati and M. Lentari, "Penerapan metode Min-Max untuk Minimasi Stockout dan Overstock persediaan bahan baku," Jurnal INTECH Teknik Industri Universitas SerangRaya, 2022.

[3] D. Shamir, "The hidden costs of poor inventory management: How much are you really losing? ," ToolsGroup. Accessed: Dec. 23, 2024.

[4] V. Nurcahyawati, J. Wibowo, and R. A. Brahmantyo, "Manajemen Persediaan Menggunakan Metode Safety Stock dan Reorder Point," Jurnal Sains dan Informatika, Jun. 2023.

[5] S. krishna C. Tulli, "Comparative Analysis of Traditional and AI-based Demand Forecasting Models.," International Journal of Emerging Trends in Science and Technology, pp. 6933–6956, Jun. 2020.

[6] N. Ayyıldız, Prediction of Stock Market Index Movements with Machine Learning. Özgür Yayınları, 2023.

[7] Y. Matsuo, Y. LeCun, and M. Sugiyama, "Deep learning, reinforcement learning, and world models," Apr. 2022, Accessed: Dec. 05, 2024.

[8] C. A. H. Hutagalung, G. A. Rosalind, D. M. S. Tuhu, and A. Agustianingsih, "Wholesale Inventory Management Optimization: Methodological Approach with XGBoost, SVR, and Random Forest Algorithms," Brilliance: Research of Artificial Intelligence, vol. 3, no. 2, pp. 369–377, Dec. 2023.

[9] P. Ganguly and I. Mukherjee, "Enhancing Retail Sales Forecasting with Optimized Machine Learning Models," Oct. 2024.

[10] M. O. Akinsolu and K. Zribi, "A Generalized Framework for Adopting Regression-Based Predictive Modeling in Manufacturing Environments," Inventions, vol. 8, no. 1, Feb. 2023.

[11] E. Retnoningsih and R. Pramudita, "Mengenal Machine Learning Dengan Teknik Supervised dan Unsupervised Learning Menggunakan Python," Bina Insani ICT Journal, vol. 7, no. 2, pp. 156–165, 2020.

[12] E. Erlin, Y. Desnelita, N. Nasution, L. Suryati, and F. Zoromi, "Dampak SMOTE terhadap Kinerja Random Forest Classifier berdasarkan Data Tidak seimbang," MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer, vol. 21, no. 3, pp. 677–690, Jul. 2022.

[13] S. Nur Maharani, B. Sugeng, and M. Mahbubi Ali, "Bank Soundness Level Prediction: ANFIS vs Deep Learning," Journal of Applied Data Sciences, vol. 4, no. 3, pp. 175–189, 2023.

[14] J. A Ilemobayo and D. O. J., "Hyperparameter Tuning in Machine Learning: A Comprehensive Review," Journal of Engineering Research and Reports, vol. 26, no. 6, pp. 388–395, Jun. 2024.

[15] M. Bastomi, "Analisis Metode Economic Order Quantity, Safety Stock, Reorder Point, Dan Cost Of Inventory Dalam Mengoptimalkan Manajemen Persediaan Umkm Bakso Pedas," Indonesian Journal Of Contemporary Multidisciplinary Research, 2023.

[16] E. Winata and I. Gusti Ngurah Alit Widana Putra, "Pengembangan Aplikasi Manajemen Persediaan untuk Meningkatkan Efisiensi Operasional Inventory Management Application Development to Improve Operational Efficiency," Jurnal Teknologi dan Informasi, 2024.