

Prediksi Volume Penjualan pada Retail Sembako Menggunakan Pemodelan XGBoost

Alza Noor Ibrahim¹ dan Dhea Qurrotun Nada²

^{1,2}Program Studi S1 Teknik Industri, Universitas Negeri Malang
Jalan Semarang 5, Kota Malang, Indonesia, 65145

Correspondence: Rudi Nurdiansyah (rudi.nurdiansyah.ft@um.ac.id)

Received: 01 July 2025 – Revised: 30 July 2025 - Accepted: 30 Aug 2025 - Published: 30 Sept 2025

Abstrak. Manajemen inventaris pada retail sembako menghadapi tantangan ketidakakuratan ramalan permintaan yang menyebabkan *overstock* atau *stockout*, sehingga mengganggu efisiensi operasional. Penelitian ini bertujuan mengembangkan model prediksi volume penjualan menggunakan algoritma *Extreme Gradient Boosting* (XGBoost) untuk meningkatkan akurasi manajemen stok. Metode yang digunakan meliputi akuisisi dan *preprocessing* data penjualan historis selama satu tahun dari Kaggle.com untuk empat kategori produk: Air Mineral, Minyak Goreng, Susu, dan Roti. Data tersebut kemudian dibagi menjadi data latih (80%) dan data uji (20%) untuk melatih model XGBoost. Kinerja prediktif model dievaluasi secara kuantitatif menggunakan metrik *Root Mean Squared Error* (RMSE). Hasil penelitian menunjukkan bahwa model XGBoost mampu memprediksi volume penjualan dengan tingkat akurasi yang bervariasi. Performa terbaik dicapai pada produk dengan permintaan stabil seperti Roti (RMSE 5.54) dan Minyak Goreng (RMSE 6.78), sementara performa lebih rendah teridentifikasi pada produk dengan permintaan sangat fluktuatif seperti Air Mineral (RMSE 16.04) dan Susu (RMSE 12.24). Sebagai solusi praktis untuk menutupi kelemahan prediksi, strategi penambahan *alert range* terbukti mampu meningkatkan tingkat pemenuhan permintaan secara signifikan. Sebagai contoh, penambahan 15 unit pada prediksi Roti mampu mencapai pemenuhan permintaan hingga 100%, sementara penambahan 20 unit pada Susu meningkatkan pemenuhan hingga 97,22%. Kombinasi antara prediksi XGBoost dan strategi *alert range* terbukti memiliki potensi besar dalam mengoptimalkan manajemen inventaris.

Kata kunci: XGBoost, Prediksi Penjualan, Manajemen Inventaris, Retail Sembako

PENDAHULUAN

Manajemen inventaris yang efektif merupakan faktor operasional yang krusial dalam industri retail sembako. Berbagai metode tradisional telah digunakan dalam manajemen persediaan, seperti peramalan menggunakan rata-rata pergerakan (*moving average*), model pemesanan ulang berbasis titik tertentu (*reorder point*), dan metode deterministik yang bergantung pada *input* manual (Salih et al., 2023). Meskipun metode-metode tersebut cukup umum, namun sering kali terbatas oleh ketidakmampuan dalam menangani fluktuasi permintaan yang dinamis (Hu & Han, 2024). Hal ini dapat menyebabkan masalah serius seperti *overstock* (kelebihan stok) atau *stockout* (kehabisan stok), yang pada gilirannya meningkatkan biaya dan mengurangi efisiensi operasional (Rakholia et al., 2025). Penelitian sebelumnya menunjukkan bahwa tingkat ketidakakuratan dalam manajemen stok pada retail sembako bisa mencapai 30-40%, yang mengarah pada pengelolaan stok yang tidak optimal (Lara & Huachez, 2024).

Seiring kemajuan teknologi, metode *machine learning* (pembelajaran mesin) mulai diterapkan dalam manajemen persediaan untuk mengatasi keterbatasan metode tradisional. Menurut Murdiansyah (2024), salah satu algoritma *machine learning* yang paling menjanjikan adalah XGBoost (*Extreme Gradient Boosting*), dikarenakan efektif dalam berbagai aplikasi prediktif, termasuk analisis data besar, serta mampu menangani ketidakpastian dan variabilitas permintaan secara lebih efisien dibandingkan dengan model lain seperti *Random Forest* atau *Support Vector Machine* (SVM) (Sangeetha et al., 2024). Keunggulan XGBoost terletak pada kemampuannya untuk memberikan prediksi yang lebih akurat dengan lebih sedikit parameter yang perlu disesuaikan, serta efisiensinya dalam mengoptimalkan kesalahan prediksi (Sun et al., 2021). Dalam konteks retail sembako, di mana fluktuasi permintaan sering terjadi, kemampuan XGBoost untuk mengatasi data yang tidak terstruktur dan memberikan prediksi yang lebih tepat sangat penting (Shrivastava et al., 2024). Selain itu, XGBoost mampu meminimalkan kesalahan prediksi, yang sangat krusial dalam pengelolaan stok, di mana kesalahan besar dalam prediksi dapat berdampak signifikan terhadap operasi retail sembako (Sim & Wei, 2023).

Dalam penelitian ini, XGBoost digunakan untuk memprediksi volume penjualan harian pada retail sembako. Model ini dievaluasi menggunakan *Root Mean Square Error* (RMSE), yang memberikan indikasi akurasi prediksi secara keseluruhan (Singh et al., 2022). RMSE digunakan sebagai ukuran untuk menilai ketepatan model dalam memprediksi volume penjualan dan memastikan bahwa model ini dapat digunakan untuk mengoptimalkan manajemen persediaan, mengurangi risiko *stockout*, dan meningkatkan efisiensi operasional retail sembako.

Dengan menggunakan pendekatan berbasis XGBoost, penelitian ini bertujuan untuk mengembangkan solusi yang lebih efektif dalam memprediksi volume penjualan pada retail sembako.

MASALAH

Ketidakakuratan dalam memprediksi volume penjualan pada industri retail sembako mencapai 30-40%, Tingkat kesalahan yang tinggi ini secara langsung memperburuk efisiensi operasional dan menyebabkan kerugian finansial (Lara & Huachez, 2024). Tanpa adanya sistem prediksi volume penjualan yang akurat, pengelolaan inventaris menjadi tidak optimal (Rakholia et al., 2025). Oleh karena itu, diperlukan solusi berbasis *machine learning* untuk meningkatkan akurasi manajemen stok.

METODE PELAKSANAAN

Dataset

Data yang digunakan diperoleh dari *database* Kaggle.com dengan periode data dimulai dari 26 Februari 2024 hingga 24 Februari 2025 yang memiliki kurun waktu 1 tahun. Fokus penelitian pada empat produk sembako: Air mineral, Minyak goreng, Susu, dan Roti. Keempatnya dipilih karena memiliki kelengkapan data yang tinggi serta mewakili berbagai pola permintaan dari yang stabil hingga fluktuatif, sehingga ideal untuk menguji ketangguhan model (Nguyen et al., 2024). Rincian setiap kolom data historis ditunjukkan pada Tabel 1.

Tabel 1. Data Historis

INFORMASI	KETERANGAN
Tanggal Penjualan	Waktu atau tanggal terjadinya transaksi penjualan.
ID Sembako	Angka spesial sebagai kluster sembako
Jumlah Barang Terjual/ <i>Sales Volume</i>	Jumlah produk yang terjual pada hari tertentu.
Stok Tersedia	Jumlah stok yang tersedia di toko pada setiap hari.
Inventory Masuk	Produk yang masuk ke dalam stok toko pada periode tertentu.
Inventory Keluar	Produk yang keluar dari stok akibat penjualan.


Preprocessing Data

Data yang diperoleh diolah melalui beberapa tahap *preprocessing* sebelum digunakan untuk pelatihan model. Data dibersihkan untuk menghilangkan *missing values* dan menangani data yang tidak konsisten. Selain itu, data akan dinormalisasi supaya berada dalam rentang yang sesuai untuk proses pemodelan. Selanjutnya, data akan dibagi menjadi dua set: pelatihan (*training set*) dan pengujian (*testing set*) dengan rasio 80:20 (El Morr et al., 2022).

Model XGBoost

XGBoost merupakan *gradient boosting* yang populer dalam dunia data *science* karena kemampuannya dalam menangani *dataset* yang besar, meminimalkan *overfitting*, dan menghasilkan prediksi yang akurat (Pang et al., 2024). Model ini menggunakan algoritma pohon keputusan sebagai basis, yang kemudian ditingkatkan secara iteratif untuk meminimalkan kesalahan model melalui proses boosting. Tahapan dalam penerapan model XGBoost dapat dilihat pada Gambar 1 yang mengilustrasikan proses yang dimulai dari persiapan data, meliputi pemisahan *dataset* menjadi data latih (80%) dan uji (20%), serta tahap *preprocessing*. Selanjutnya, model dilatih secara iteratif, di mana dilakukan evaluasi untuk menyeleksi fitur yang paling signifikan (*feature importance*) dan menyetel

hyperparameter (fine-tune) hingga mencapai performa optimal. Proses ini diakhiri dengan evaluasi performa akhir untuk menghasilkan sebuah model final yang telah teroptimasi.



Gambar 1. Tahapan Model XGBoost
Sumber: (Dong et al., 2020)

Selama *training*, optimasi *hyperparameter* dilakukan melalui *cross-validation* untuk menemukan nilai optimal, seperti *n_estimators*, *learning_rate*, dan *max_depth*. Parameter yang disajikan pada Tabel 2 digunakan dalam model final karena kombinasi tersebut menghasilkan performa model yang paling optimal, dengan tingkat kesalahan prediksi terendah selama proses validasi.

Tabel 2. Parameter Model XGBoost

PARAMETER	NILAI
<i>n_estimators</i>	100
<i>learning_rate</i>	0.3
<i>max_depth</i>	10
<i>subsample</i>	0.6
<i>gamma</i>	0.05

Sumber: (Dong et al., 2020)

Secara matematis, XGBoost bekerja secara aditif seperti yang ditunjukkan pada Persamaan (1), di mana fungsi prediksi pada iterasi ke- t ($f_t(x)$) dibentuk dengan menambahkan pohon keputusan baru ($Tree_t(x)$) ke fungsi prediksi dari iterasi sebelumnya ($f_{t-1}(x)$). Kontribusi dari setiap pohon baru ini diskalakan oleh η (*eta*), yang nilainya diatur oleh parameter *learning_rate* pada Tabel 2 untuk mengontrol laju pembelajaran.

$$Lf_t(x) = f_{t-1}(x) + \eta \cdot Tree_t(x) \quad (1)$$

Tujuan utama dari model XGBoost adalah meminimalkan fungsi objektif ($L(\theta)$), yang disajikan pada Persamaan (2). Terdiri dari dua komponen, yaitu komponen kerugian

(ℓ) yang mengukur kesalahan prediksi dari total kesalahan antara nilai aktual (y_i) dan nilai prediksi ($f_t(x_i)$) untuk seluruh data observasi (n). Adapun komponen term regularisasi (Ω), yang mencegah *overfitting* dari setiap pohon keputusan (f_k) yang dibangun. Jumlah total pohon yang dievaluasi dilambangkan dengan (T), nilainya ditentukan secara langsung oleh *hyperparameter* dan $n_estimators$. Sementara itu, parameter lain dari Tabel 2 seperti max_depth dan $gamma$ berperan penting dalam mengontrol struktur dan kompleksitas setiap pohon.

$$L(\theta) = \sum_{i=1}^n \ell(y_i, f_t(x_i)) + \sum_{k=1}^T \Omega(f_k) \quad (2)$$

Evaluasi Model


Evaluasi kinerja dilakukan menggunakan metrik *Root Mean Squared Error* (RMSE) untuk mengukur akurasi prediksi volume penjualan. RMSE digunakan untuk membandingkan perbedaan antara nilai yang diprediksi dan nilai aktual. Semakin rendah nilai RMSE, semakin baik kinerja model dalam memprediksi permintaan barang (Hodson, 2022). Secara matematis, Persamaan (3) dihitung dengan mencari selisih antara nilai aktual (y_i) dengan nilai yang diprediksi oleh model ($\hat{y}_i$) untuk setiap titik data. Hasilnya dirata-ratakan dan membaginya dengan jumlah total observasi (n),

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

HASIL DAN PEMBAHASAN

Analisis Fluktuasi Stok

Analisis awal dilakukan dengan mengamati kondisi stok *residual* dari setiap kategori produk, yaitu Air Mineral, Minyak Goreng, Susu, dan Roti. Stok *residual* merupakan selisih antara stok yang tersedia dengan volume penjualan harian. Selama periode pengamatan dari 26 Februari 2024 hingga 24 Februari 2025, setiap kategori produk menunjukkan pola fluktuasi yang khas. Seperti yang terlihat pada Gambar 2, stok *residual* mengalami fluktuasi yang tajam (menjauhi angka 0), terutama pada produk Air Mineral, yang menunjukkan adanya hari-hari dengan kelebihan stok signifikan dan hari lain yang mendekati kondisi kehabisan stok (*stockout*).




Gambar 2. Sembako Residual Inventory


Fluktuasi stok yang signifikan pada Grafik tersebut menjelaskan bahwa manajemen persediaan retail sembako menghadapi tantangan nyata pada ketidakstabilan dalam permintaan yang mempengaruhi ketersediaan barang. Variabilitas yang tinggi sering menyebabkan stok berlebih atau justru kekurangan (Rakholia et al., 2025). Kondisi ini menegaskan bahwa pendekatan manajemen stok yang mengandalkan prediksi manual atau metode statistik konvensional tidak cukup efektif dalam memenuhi tuntutan efisiensi dan keberlanjutan operasional, sehingga diperlukan sistem prediksi yang mampu beradaptasi dengan pola permintaan yang dinamis (Nweje & Taiwo, 2025).

Prediksi Volume Penjualan Menggunakan Model XGBoost


Penggunaan algoritma XGBoost dalam penelitian ini menunjukkan potensi yang menjanjikan dalam mengatasi tantangan tersebut. Visualisasi hasil prediksi terhadap data aktual disajikan dalam Gambar 3, yang membandingkan prediksi model (garis merah) dengan volume penjualan aktual (garis hitam). Dari visualisasi tersebut, dapat diamati bahwa model mampu mengikuti pola permintaan dengan cukup baik, khususnya pada produk Roti (Gambar 3d), di mana terdapat kesesuaian yang tinggi antara prediksi dan nilai aktual. Sebaliknya, prediksi pada Air Mineral (Gambar 3a) menunjukkan selisih yang lebih besar, yang mengartikan lebih sulitnya dalam memodelkan permintaan pada kategori air mineral (Lutoslawski et al., 2021).




(a)



(b)



(b)



(c)


Gambar 3. Prediksi Sales Volume Sembako oleh Model XGBoost (a) Air mineral, (b) Minyak Goreng, (c) Susu, (d) Roti

Evaluasi kuantitatif terhadap model dilakukan menggunakan metrik *Root Mean Squared Error* (RMSE) melalui persamaan (3). Hasilnya menunjukkan nilai RMSE tertinggi pada produk Air Mineral sebesar 16.04, diikuti oleh Susu sebesar 12.24, Minyak Goreng sebesar 6.78, dan Roti dengan nilai RMSE terendah yaitu 5.54. Meskipun terdapat variasi akurasi, model XGBoost dapat dianggap efektif, karena mampu memberikan prediksi kuantitatif yang lebih baik dibandingkan metode tradisional non-algoritmik (R et al., 2023). Hasil ini mengindikasikan bahwa model memiliki akurasi tertinggi pada produk dengan pola permintaan stabil seperti Roti, dan cenderung kurang akurat pada produk dengan permintaan tidak menentu seperti Air Mineral (Lutoslawski et al., 2021). Performa model yang lebih lemah pada kategori Air Mineral (RMSE 16.04) menunjukkan bahwa volatilitas permintaan yang tinggi, yang kemungkinan dipengaruhi oleh faktor eksternal, sehingga memerlukan pendekatan prediksi yang tidak hanya mengandalkan data historis. Temuan ini sejalan dengan penelitian Sun et al (2021), yang menyatakan bahwa meskipun XGBoost unggul dalam menangkap tren jangka pendek, tetapi juga memiliki keterbatasan dalam memprediksi lonjakan permintaan yang mendadak dan tidak beraturan. Sebagai perbandingan, algoritma lain seperti LSTM (*Long Short-Term Memory*) atau Prophet, yang secara arsitektur dirancang untuk data deret waktu, berpotensi menghasilkan nilai RMSE yang lebih kecil pada kasus seperti ini (Junior et al., 2021). Oleh karena itu, eksplorasi model-model tersebut dapat menjadi langkah selanjutnya untuk meningkatkan akurasi prediksi, khususnya pada produk dengan volatilitas tinggi.


Mitigasi Risiko dengan Strategi *Alert Range*

Sebagai langkah mitigasi terhadap potensi kesalahan prediksi, penelitian ini menerapkan pendekatan *alert range* dengan menambahkan sejumlah unit tetap pada hasil prediksi harian. Penentuan ambang batas (*threshold*) *alert range* ditetapkan berdasarkan analisis data historis, seperti rata-rata permintaan lampau yang tidak terpenuhi (Sivaraman, 2024). Strategi ini bertujuan untuk membentuk stok pengaman agar dapat memenuhi permintaan aktual yang melebihi prediksi (Sun et al., 2021). Dalam mengantisipasi risiko kekurangan stok akibat ketidakakuratan prediksi, strategi penambahan *alert range* terbukti efektif sebagai langkah mitigative (Sivaraman, 2024).


Visualisasi dari efek penambahan *alert range* pada produk Minyak goreng ditampilkan pada Gambar 4, yang menunjukkan bagaimana setiap kenaikan 5, 10, 15, hingga 20 unit pada prediksi produk Minyak goreng dapat meningkatkan tingkat pemenuhan permintaan aktual.




(a)



(b)



(c)



(d)

Gambar 4. Hubungan Pengaturan *Alert Range* dan Pemenuhan Permintaan (a) 5U, (b) 10U, (c) 15U, (d) 20U

Hasil kuantitatif dari strategi ini disajikan pada Tabel 3. Data menunjukkan efektivitas penambahan unit yang berbeda antar produk. Pada produk Roti, penambahan 10 unit cukup untuk memenuhi 97% permintaan, dan penambahan 15 unit mencapai 100%. Untuk Minyak Goreng, penambahan 10 unit memenuhi 94,80% permintaan, dan meningkat menjadi 97,40% dengan tambahan 15 unit. Kategori Susu menunjukkan peningkatan signifikan dari 64,44% (tambahan 5 unit) menjadi 97,22% (tambahan 20 unit). Namun, pada Air Mineral, meskipun telah ditambahkan hingga 20 unit, tingkat pemenuhan maksimal hanya mencapai 88,82%.

Tabel 3. Penambahan *Alert Range* dan Persentase Pemenuhan *Sales Volume*

<i>Set up alert range</i> sembako	5 unit (%)	10 unit (%)	15 unit (%)	20 unit (%)
Air mineral	63.74%	73.11%	81.26%	88.82%
Minyak goreng	83.11%	94.80%	97.40%	97.40%
Susu	64.44%	79.44%	87.77%	97.22%
Roti	79.72%	97%	100%	100%

Hal ini mengindikasikan bahwa produk dengan permintaan sangat fluktuatif membutuhkan pendekatan yang lebih kompleks dalam manajemen stoknya, karena penambahan stok cadangan memiliki batas efektivitas dan tidak dapat sepenuhnya menutupi lonjakan permintaan yang acak (Raghuram et al., 2023). Meskipun strategi *alert range* menawarkan solusi praktis, penting untuk menimbang efisiensi biaya, karena penambahan stok berlebihan berisiko menyebabkan *overstocking* dan biaya penyimpanan (Khashu, 2025). Oleh karena itu, besaran *alert range* harus disesuaikan dengan karakteristik setiap produk, di mana data pada Tabel 3 dapat menjadi acuan kuantitatif bagi manajer operasional.

KESIMPULAN

Penelitian ini membuktikan bahwa model XGBoost efektif untuk memprediksi prediksi volume penjualan, dengan performa terbaik pada produk dengan pola permintaan yang stabil, seperti Roti (RMSE 5.54) dan Minyak Goreng (RMSE 6.78). Sebaliknya, performa model lebih lemah terhadap produk dengan permintaan yang fluktuatif, yang terlihat pada nilai RMSE yang lebih tinggi untuk Air Mineral (16.04) dan Susu (12.24). Penelitian ini juga menunjukkan bahwa penerapan strategi mitigasi berupa *alert range* mampu meningkatkan pemenuhan permintaan secara signifikan yang bisa mencapai 100% pada produk roti. Dengan demikian, kombinasi antara prediksi XGBoost dan kebijakan *alert range* menawarkan kerangka kerja yang solid dan aplikatif untuk optimalisasi inventaris

pada retail sembako. Penelitian ini memiliki keterbatasan karena hanya berbasis pada data historis penjualan, sehingga disarankan untuk mengintegrasikan data eksternal seperti cuaca atau hari libur untuk meningkatkan akurasi prediksi lebih lanjut,

UCAPAN TERIMA KASIH

Penelitian ini didanai oleh PNPB Universitas Negeri Malang tahun 2025 melalui Hibah Inovasi Mahasiswa. Kami berterima kasih atas dukungan yang memungkinkan penelitian ini berjalan lancar. Terima kasih juga kepada Bapak Rudi Nurdiansyah selaku pembimbing atas bimbingan dan arahnya dalam menyelesaikan penelitian ini.

DAFTAR PUSTAKA

- Díaz Lara, M. I., & Puma Huachez, M. J. (2024). *Logistics optimization and inventory control in Peruvian grocery companies*. *Sapienza: International Journal of Interdisciplinary Studies*, 5(3), e24061. <https://doi.org/10.51798/sijis.v5i3.788>
- Dong, W., Huang, Y., Lehane, B., & Ma, G. (2020). *XGBoost algorithm-based prediction of concrete electrical resistivity for structural health monitoring*. *Automation in Construction*, 114, 103155. <https://doi.org/10.1016/j.autcon.2020.103155>
- El Morr, C., Jammal, M., Ali-Hassan, H., & El-Hallak, W. (2022). Data Preprocessing. In C. El Morr, M. Jammal, H. Ali-Hassan, & W. El-Hallak, *Machine Learning for Practical Decision Making* (Vol. 334, pp. 117–163). Springer International Publishing. https://doi.org/10.1007/978-3-031-16990-8_4
- Hodson, T. O. (2022). *Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not*. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Hu, L., & Han, W. (2024). *Research on Supply Chain Demand Forecasting and Dynamic Adjustment Model Based on Big Data and Artificial Intelligence*. *2024 International Conference on Interactive Intelligent Systems and Techniques (IIST)*, 153–159. <https://doi.org/10.1109/iist62526.2024.00100>
- Khashu, K. (2025). *Overstocking in Healthcare: Challenges and Strategic Solutions Leveraging Process and Technology Advancements*. *International Journal for Research in Applied Science and Engineering Technology*, 13(1), 120–123. <https://doi.org/10.22214/ijraset.2025.66200>
- Lutoslawski, K., Hernes, M., Radomska, J., Hajdas, M., Walaszczyk, E., & Kozina, A. (2021). *Food Demand Prediction Using the Nonlinear Autoregressive Exogenous Neural Network*. *IEEE Access*, 9, 146123–146136. <https://doi.org/10.1109/access.2021.3123255>
- Sangeetha G, Mr. Harshavardhan S V, Mr. Allen Joshua L, & Mr. Anirudh S M. (2024). *Predictive Analysis for Supply Chain Management Using Extreme Gradient Boost Classifier*. *International Journal of Advanced Research in Science, Communication and Technology*, 531–534. <https://doi.org/10.48175/ijarsct-15987>

- Murdiansyah, D. T. (2024). *Prediksi Stroke Menggunakan Extreme Gradient Boosting. JIKO (Jurnal Informatika Dan Komputer)*, 8(2), 419. <https://doi.org/10.26798/jiko.v8i2.1295>
- Pang, Y., Wang, X., Tang, Y., Guobin, G., Chen, J., Yang, B., Ning, L., Bao, C., Zhou, S., Cao, X., & Wen, X. (2024). *A traffic accident early warning model based on XGBOOST*. In Q. Lu & W. Zhang (Eds.), *Fourth International Conference on Advanced Algorithms and Neural Networks (AANN 2024)* (p. 120). SPIE. <https://doi.org/10.1117/12.3049832>
- R, M. R. V. V., N, S., Shankar Reddy, S., Rao Kurada, R., Mahaboob Hussain, S., & L Sameera, E. (2023). *A Robust XG-Boost Machine Learning Model for Water Quality Estimation System by Leveraging with Chi-Square Forward Sequential Feature Selection Technique*. *2023 International Conference on Ambient Intelligence, Knowledge Informatics and Industrial Electronics (AIKIE)*, 1–7. <https://doi.org/10.1109/aikiie60097.2023.10390370>
- Raghuram, P., S, B., Manivannan, R., Anand, P. S. P., & Sreedharan, V. R. (2023). *Modeling and Analyzing the Inventory Level for Demand Uncertainty in the VUCA World: Evidence From Biomedical Manufacturer*. *IEEE Transactions on Engineering Management*, 70(8), 2944–2954. <https://doi.org/10.1109/tem.2022.3201440>
- Rakholia, K. R., Chandraprabh, C., Ramesh, R., Rao, Kolli. S., Punitha, S., & Kumar, M. G. V. (2025). *Optimizing Inventory Management Through Demand Forecasting: A Data-Driven Approach for Enhanced Supply Chain Efficiency*. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5076111>
- Sabah Salih, H., Ghazi, M., & Aljanabi, M. (2023). *Implementing an Automated Inventory Management System for Small and Medium-sized Enterprises*. *Iraqi Journal for Computer Science and Mathematics*, 238–244. <https://doi.org/10.52866/ijcsm.2023.02.02.021>
- Shrivastava, A., Kotiyal, A., Habelalmateen, M. I., Rana, A., Devi, V. S. A., Rao, B. D., & Bansal, S. (2024). *Leveraging XGBoost for Predictive Analytics in Healthcare: Enhancing Disease Diagnosis*. *2024 7th International Conference on Contemporary Computing and Informatics (IC3I)*, 1666–1672. <https://doi.org/10.1109/IC3I61595.2024.10829136>
- Sim, D. Y. Y., & Wei, Z. (2023). *XGBoost Regression Algorithms for Efficient Predictions on Inventory Sales and Management*. *2023 6th International Conference on Electronics and Electrical Engineering Technology (EET)*, 66–71. <https://doi.org/10.1109/EEET61723.2023.00033>
- Singh, A. K., Kumar, P., Ali, R., Al-Ansari, N., Vishwakarma, D. K., Kushwaha, K. S., Panda, K. C., Sagar, A., Mirzania, E., Elbeltagi, A., Kuriqi, A., & Heddami, S. (2022). *An Integrated Statistical-Machine Learning Approach for Runoff Prediction*. *Sustainability*, 14(13), 8209. <https://doi.org/10.3390/su14138209>
- Sivaraman, H. (2024). *Adaptive Thresholding in ML-Driven Alerting Systems for Reducing False Positives in Production Environment*. *INTERNATIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*, 08(12), 1–6. <https://doi.org/10.55041/ijsem11938>

- Sun, X., Xu, Z., Feng, Y., Yang, Q., Xie, Y., Wang, D., & Yu, Y. (2021). *RBC Inventory-Management System Based on XGBoost Model*. *Indian Journal of Hematology and Blood Transfusion*, 37(1), 126–133. <https://doi.org/10.1007/s12288-020-01333-5>
- Time Series Forecasting in Retail Sales Using LSTM and Prophet. (2021). In C. Junior, P. Gusmão, J. Moreira, & A. M. M. Tome, *Advances in Business Information Systems and Analytics* (pp. 241–262). IGI Global. <https://doi.org/10.4018/978-1-7998-6985-6.ch011>
- Tuan Ngoc Nguyen, Mahfuz Haider, Afjal Hossain Jisan, Md Azad Hossain Raju, Touhid Imam, Md Munsur Khan, & Abdullah Evna Jafar. (2024). *Product Demand Forecasting with Neural Networks and Macroeconomic Indicators: A Comparative Study among Product Categories*. *Journal of Business and Management Studies*, 6(2), 170–175. <https://doi.org/10.32996/jbms.2024.6.2.17>
- Uche Nweje & Moyosore Taiwo. (2025). *Leveraging Artificial Intelligence for predictive supply chain management, focus on how AI- driven tools are revolutionizing demand forecasting and inventory optimization*. *International Journal of Science and Research Archive*, 14(1), 230–250. <https://doi.org/10.30574/ijrsra.2025.14.1.0027>

