

## Model Prediksi Permintaan Produk Berbasis Big Data Analytics untuk Pengendalian Persediaan Multi-Produk

Almayandi, Hanapi, Haerul Azmi <sup>1</sup>

**Abstrak:** Penelitian ini bertujuan mengembangkan model prediksi permintaan produk berbasis Big Data Analytics untuk meningkatkan efektivitas pengendalian persediaan multi-produk. Permasalahan utama terletak pada rendahnya akurasi metode prediksi tradisional dalam menangani data kompleks dan dinamika permintaan yang tinggi. Penelitian ini menggunakan pendekatan kuantitatif berbasis data-driven dengan memanfaatkan data historis penjualan, perilaku konsumen, serta faktor eksternal seperti musim dan promosi. Model yang dikembangkan mengintegrasikan metode statistik, machine learning, dan deep learning dalam kerangka hybrid untuk menangkap pola linear dan non-linear secara simultan. Tahapan penelitian meliputi pengumpulan data, preprocessing, feature engineering, pelatihan model, serta evaluasi menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE). Selain itu, teknik ensemble learning dan clustering diterapkan untuk meningkatkan akurasi dan stabilitas model. Hasil penelitian menunjukkan bahwa model hybrid berbasis Big Data Analytics mampu menghasilkan prediksi dengan tingkat akurasi lebih tinggi dibandingkan model tunggal. Model ini juga mampu menangkap interdependensi antar produk dalam sistem multi-produk secara lebih efektif. Integrasi hasil prediksi dengan kebijakan pengendalian persediaan seperti safety stock dan reorder point menunjukkan peningkatan efisiensi operasional melalui penurunan risiko overstock dan stockout. Selain itu, sistem yang dikembangkan mampu merespons perubahan permintaan secara lebih cepat dan adaptif. Penelitian ini memberikan kontribusi dalam pengembangan model prediksi yang tidak hanya akurat, tetapi juga aplikatif dalam mendukung pengambilan keputusan inventory di era digital.

**Kata Kunci:** Big Data Analytics, Prediksi Permintaan, Machine Learning, Pengendalian Persediaan, Multi-Produk

---

**Abstract:** *This study aims to develop a product demand forecasting model based on Big Data Analytics to improve the*

---

<sup>1</sup> Program Studi Teknik Industri, Universitas Jenderal Achmad Yani, Cimahi, Indonesia, [Almayandi63@gmail.com](mailto:Almayandi63@gmail.com)

effectiveness of multi-product inventory control. The main problem lies in the low accuracy of traditional forecasting methods in handling complex data and high demand variability. This study employs a quantitative, data-driven approach by utilizing historical sales data, consumer behavior, and external factors such as seasonality and promotions. The proposed model integrates statistical methods, machine learning, and deep learning within a hybrid framework to simultaneously capture linear and non-linear patterns. The research stages include data collection, preprocessing, feature engineering, model training, and evaluation using Mean Absolute Error (MAE) and Root Mean Square Error (RMSE). In addition, ensemble learning and clustering techniques are applied to enhance model accuracy and stability. The results indicate that the hybrid model based on Big Data Analytics produces higher prediction accuracy compared to single models. The model effectively captures interdependencies among products within a multi-product system. The integration of forecasting results with inventory control policies, such as safety stock and reorder point, improves operational efficiency by reducing the risks of overstock and stockouts. Furthermore, the developed system responds more quickly and adaptively to demand fluctuations. This study contributes to the development of forecasting models that are not only accurate but also practical in supporting inventory decision-making in the digital era.

**Keywords:** *Big Data Analytics, Demand Forecasting, Machine Learning, Inventory Control, Multi-Product*

## A. Pendahuluan

Transformasi digital telah mengubah cara organisasi mengelola rantai pasok dan pengendalian persediaan. Volume data yang terus meningkat, kecepatan aliran informasi, serta keragaman sumber data mendorong perusahaan untuk mengadopsi pendekatan berbasis Big Data Analytics dalam pengambilan keputusan. Dalam konteks ini, prediksi permintaan produk menjadi aspek kritis yang menentukan efisiensi operasional dan daya saing perusahaan. Pemanfaatan data historis, perilaku konsumen, serta faktor eksternal seperti musim dan promosi memungkinkan organisasi menghasilkan prediksi yang lebih akurat dan adaptif terhadap dinamika pasar (Thi, 2025; Duvaasi, 2025).

Namun, metode prediksi tradisional masih banyak digunakan dalam praktik industri. Pendekatan seperti Autoregressive Integrated Moving Average (ARIMA) atau metode statistik lainnya memiliki keterbatasan dalam menangkap pola non-linear dan interaksi kompleks antar variabel. Studi menunjukkan bahwa model statistik konvensional cenderung kurang responsif terhadap perubahan cepat dalam permintaan, terutama pada lingkungan bisnis yang dinamis seperti e-commerce dan retail modern (Murni et al., 2025; Chen, 2024). Kondisi ini memicu pengembangan metode baru berbasis machine learning dan deep learning yang mampu memproses data dalam skala besar dan kompleks.

Pendekatan machine learning seperti Random Forest, Decision Tree, dan Neural Network telah menunjukkan peningkatan akurasi dalam prediksi permintaan dibandingkan metode tradisional. Model ini mampu menangkap hubungan non-linear dan interaksi antar variabel yang tidak dapat diidentifikasi oleh metode statistik klasik (Mohan & Kurian, 2023; Nagarajan et al., 2025). Selain itu, penggunaan deep learning seperti Long Short-Term Memory (LSTM) dan Bidirectional LSTM memberikan keunggulan dalam mengolah data time series dengan pola temporal yang kompleks (Abualurouq et al., 2024). Model ini terbukti mampu meningkatkan akurasi prediksi dengan memanfaatkan dependensi jangka panjang dalam data permintaan.

Seiring dengan perkembangan tersebut, muncul pendekatan hybrid yang menggabungkan metode statistik dan machine learning. Model hybrid seperti ARIMA-SVR-PSO dan Prophet-XGBoost menunjukkan performa yang lebih baik dibandingkan model tunggal karena mampu mengintegrasikan keunggulan masing-masing metode (Ai et al., 2024; Elorza et al., 2024). Penelitian lain juga menunjukkan bahwa pendekatan ensemble deep learning mampu meningkatkan stabilitas dan akurasi prediksi melalui kombinasi beberapa model (Seyedan et al., 2023). Dengan demikian, integrasi berbagai metode menjadi strategi penting dalam meningkatkan kualitas prediksi permintaan.

Meskipun berbagai metode telah dikembangkan, tantangan utama masih terletak pada pengendalian

persediaan multi-produk. Dalam sistem multi-produk, permintaan antar produk seringkali saling terkait, baik melalui substitusi maupun komplementaritas. Ketergantungan ini meningkatkan kompleksitas prediksi karena model harus mampu menangkap interaksi antar produk secara simultan. Model tradisional cenderung mengasumsikan independensi antar produk, sehingga menghasilkan kesalahan prediksi yang lebih tinggi (Baykal-G & Erkip, 2011). Pendekatan data-driven yang mempertimbangkan hubungan antar produk menjadi sangat penting untuk meningkatkan akurasi dalam sistem inventory yang kompleks (Schmidt & Pibernik, 2025).

Kesalahan dalam prediksi permintaan memiliki konsekuensi langsung terhadap kinerja operasional perusahaan. Prediksi yang terlalu tinggi menyebabkan overstock yang meningkatkan biaya penyimpanan dan risiko kerusakan produk. Sebaliknya, prediksi yang terlalu rendah menyebabkan stockout yang berdampak pada hilangnya peluang penjualan dan menurunnya kepuasan pelanggan (Achakzai, 2025). Oleh karena itu, akurasi prediksi permintaan menjadi faktor kunci dalam mencapai efisiensi biaya dan meningkatkan service level dalam rantai pasok (Hu & Han, 2024).

Big Data Analytics menawarkan solusi untuk mengatasi keterbatasan tersebut melalui integrasi data dari berbagai sumber. Pendekatan ini memungkinkan penggunaan data transaksi, perilaku pelanggan, tren pasar, hingga faktor eksternal secara simultan dalam proses prediksi (Olatunji, 2025). Selain itu, perkembangan teknologi memungkinkan pemrosesan data secara real-time, sehingga model prediksi dapat diperbarui secara dinamis sesuai perubahan kondisi pasar (Ankam, 2025). Implementasi model berbasis big data juga memungkinkan perusahaan meningkatkan responsivitas dan fleksibilitas dalam pengelolaan inventory.

Beberapa penelitian telah mengembangkan pendekatan berbasis clustering dan representasi data untuk meningkatkan performa model prediksi. Metode ini memungkinkan pengelompokan produk berdasarkan karakteristik tertentu, sehingga model dapat menangkap pola permintaan yang lebih spesifik dan mengurangi risiko overfitting (Li et al., 2019). Selain itu, pendekatan berbasis K-Means dan teknik clustering lainnya juga terbukti mampu

meningkatkan akurasi prediksi dengan mengelompokkan data yang memiliki pola serupa (Yang, 2023).

Di sisi lain, integrasi model prediksi dengan sistem pengendalian persediaan masih menjadi tantangan. Sebagian besar penelitian fokus pada peningkatan akurasi prediksi tanpa mengaitkannya secara langsung dengan kebijakan inventory seperti safety stock dan reorder point. Padahal, integrasi ini sangat penting untuk memastikan bahwa hasil prediksi dapat digunakan secara efektif dalam pengambilan keputusan operasional (Sekhar, 2022). Pendekatan prescriptive analytics menjadi solusi untuk menghubungkan hasil prediksi dengan kebijakan optimal dalam pengendalian persediaan (Schmidt & Pibernik, 2025).

Selain itu, penelitian terbaru menunjukkan bahwa penerapan deep learning berbasis big data dapat meningkatkan efisiensi operasional secara signifikan. Model seperti SoxNet dan DemandNet mampu menghasilkan prediksi real-time dengan tingkat akurasi yang tinggi serta efisiensi komputasi yang baik (Kalisetty, 2023). Pendekatan ini memungkinkan perusahaan mengelola inventory dalam skala besar dengan lebih efektif, terutama pada lingkungan bisnis yang memiliki volume data tinggi dan dinamika permintaan yang cepat berubah.

Meskipun demikian, masih terdapat kesenjangan penelitian yang perlu diatasi. Sebagian besar studi hanya berfokus pada single-product forecasting dan belum mempertimbangkan kompleksitas sistem multi-produk secara menyeluruh. Selain itu, integrasi antara big data analytics, machine learning, dan kebijakan inventory control masih terbatas. Penelitian yang menggabungkan ketiga aspek tersebut secara komprehensif masih jarang ditemukan. Hal ini menunjukkan adanya peluang untuk mengembangkan model prediksi yang lebih terintegrasi dan aplikatif dalam konteks pengendalian persediaan multi-produk.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan model prediksi permintaan produk berbasis Big Data Analytics yang mampu meningkatkan akurasi prediksi dalam sistem multi-produk. Model yang dikembangkan mengintegrasikan pendekatan statistik, machine learning, dan deep learning untuk

menangkap pola permintaan yang kompleks. Selain itu, penelitian ini juga mengaitkan hasil prediksi dengan kebijakan pengendalian persediaan untuk meningkatkan efisiensi operasional.

Kebaruan penelitian ini terletak pada integrasi pendekatan hybrid berbasis big data dengan sistem inventory multi-produk secara simultan. Penelitian ini tidak hanya fokus pada peningkatan akurasi prediksi, tetapi juga pada implementasi hasil prediksi dalam pengambilan keputusan inventory. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi teoritis dan praktis dalam pengembangan model prediksi permintaan yang lebih efektif dan aplikatif dalam lingkungan bisnis modern.

## **B. Metode Penelitian**

Penelitian ini menggunakan pendekatan kuantitatif berbasis data-driven untuk mengembangkan model prediksi permintaan produk dalam sistem inventory multi-produk. Pendekatan ini dipilih karena mampu mengolah data dalam jumlah besar dan menghasilkan model prediktif yang akurat serta objektif. Metode yang digunakan mengadopsi prinsip data science dan machine learning yang telah terbukti efektif dalam meningkatkan akurasi prediksi permintaan (Olatunji, 2025).

Sumber data dalam penelitian ini terdiri dari data historis penjualan, data perilaku konsumen, serta data eksternal yang memengaruhi permintaan produk. Data historis mencakup informasi penjualan per produk dalam periode waktu tertentu, sedangkan data perilaku konsumen mencakup pola pembelian dan preferensi pelanggan. Selain itu, data eksternal seperti musim, promosi, dan faktor ekonomi juga digunakan untuk meningkatkan akurasi prediksi (Murni et al., 2025; Luan, 2024). Karakteristik data yang digunakan mencerminkan konsep big data dengan volume besar, kecepatan tinggi, dan variasi yang beragam (Duvaasi, 2025).

Pengumpulan data dilakukan melalui proses data mining dari sistem enterprise resource planning (ERP) atau platform e-commerce. Data yang diperoleh kemudian diintegrasikan dalam satu sistem untuk memastikan konsistensi dan kelengkapan informasi. Tahap selanjutnya adalah

preprocessing data yang meliputi pembersihan data, normalisasi, dan transformasi variabel. Proses ini penting untuk menghilangkan noise dan memastikan kualitas data sebelum digunakan dalam pemodelan (Hu & Han, 2024).

Variabel dalam penelitian ini terdiri dari variabel independen, dependen, dan kontrol. Variabel independen mencakup data historis penjualan, faktor eksternal, dan perilaku konsumen. Variabel dependen adalah permintaan produk yang diprediksi oleh model. Variabel kontrol meliputi faktor musiman dan tren pasar yang dapat memengaruhi hasil prediksi. Struktur variabel ini memungkinkan model menangkap hubungan kompleks antara berbagai faktor yang memengaruhi permintaan.

Model prediksi yang dikembangkan menggunakan pendekatan hybrid yang menggabungkan metode statistik, machine learning, dan deep learning. Metode statistik seperti ARIMA dan SARIMAX digunakan untuk menangkap pola linear dalam data time series (Chen, 2024). Sementara itu, metode machine learning seperti XGBoost dan Random Forest digunakan untuk menangkap hubungan non-linear dan interaksi antar variabel (Murni et al., 2025; Nagarajan et al., 2025). Untuk meningkatkan performa model, digunakan pendekatan deep learning seperti LSTM dan BiLSTM yang mampu menangkap pola temporal yang kompleks dalam data permintaan (Abualroug et al., 2024; Kalisetty, 2023).

Selain itu, penelitian ini juga menerapkan teknik ensemble learning untuk menggabungkan beberapa model prediksi. Pendekatan ini bertujuan untuk meningkatkan stabilitas dan akurasi model dengan memanfaatkan keunggulan masing-masing metode (Seyedan et al., 2023). Teknik clustering juga digunakan untuk mengelompokkan produk berdasarkan karakteristik tertentu, sehingga model dapat menghasilkan prediksi yang lebih spesifik dan akurat (Li et al., 2019).

Tahapan penelitian dimulai dengan pengumpulan dan integrasi data, diikuti oleh preprocessing dan feature engineering. Feature engineering dilakukan untuk menghasilkan variabel baru yang relevan dengan pola permintaan. Selanjutnya, model dilatih menggunakan data training dan diuji menggunakan data testing. Proses ini

dilakukan secara iteratif untuk mendapatkan model dengan performa terbaik.

Evaluasi model dilakukan menggunakan beberapa metrik, yaitu Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan tingkat akurasi prediksi. Metrik ini digunakan untuk mengukur kinerja model dalam memprediksi permintaan produk secara akurat (Agarwal, 2025; Ai et al., 2024). Selain itu, dilakukan perbandingan antara model yang dikembangkan dengan model baseline untuk memastikan adanya peningkatan performa.

Model yang telah dikembangkan kemudian diintegrasikan dengan sistem pengendalian persediaan. Hasil prediksi digunakan untuk menentukan kebijakan inventory seperti safety stock dan reorder point. Pendekatan ini memungkinkan perusahaan mengoptimalkan tingkat persediaan dan mengurangi risiko overstock maupun stockout (Sekhar, 2022). Selain itu, pendekatan prescriptive analytics digunakan untuk mendukung pengambilan keputusan yang lebih optimal dalam pengelolaan inventory (Schmidt & Pibernik, 2025).

Penelitian ini juga memanfaatkan teknologi komputasi modern seperti Python dengan library TensorFlow dan Scikit-learn untuk pengembangan model. Platform big data seperti Hadoop atau Spark digunakan untuk mengelola dan memproses data dalam skala besar. Penggunaan teknologi ini memungkinkan model untuk diimplementasikan secara real-time dan scalable sesuai kebutuhan industri.

Validasi model dilakukan menggunakan teknik cross-validation untuk memastikan keandalan dan generalisasi model. Selain itu, model diuji menggunakan data real-time untuk mengevaluasi performanya dalam kondisi aktual (Kalisetty, 2023). Proses validasi ini penting untuk memastikan bahwa model yang dikembangkan tidak hanya akurat secara teoritis, tetapi juga aplikatif dalam praktik.

Dengan pendekatan metodologis ini, penelitian diharapkan mampu menghasilkan model prediksi permintaan yang akurat, adaptif, dan relevan untuk pengendalian persediaan multi-produk. Integrasi antara big data analytics, machine learning, dan kebijakan inventory menjadi kunci dalam meningkatkan efisiensi operasional dan daya saing perusahaan di era digital.

### **C. Temuan dan Pembahasan**

Penelitian ini menghasilkan model prediksi permintaan berbasis Big Data Analytics yang dirancang untuk menangani kompleksitas sistem persediaan multi-produk. Hasil pengolahan data menunjukkan bahwa integrasi data historis, perilaku konsumen, serta faktor eksternal memberikan kontribusi signifikan terhadap peningkatan kualitas prediksi. Dataset yang digunakan memiliki karakteristik volume besar, variasi tinggi, dan frekuensi pembaruan yang cepat. Setelah melalui tahap preprocessing, data menjadi lebih bersih dan terstruktur, sehingga mampu meningkatkan stabilitas proses pelatihan model.

Tahap awal analisis dilakukan dengan mengevaluasi performa model baseline berbasis metode statistik konvensional. Model ARIMA dan SARIMAX menunjukkan kemampuan yang cukup baik dalam menangkap pola musiman dan tren linear. Namun, performa model ini menurun ketika dihadapkan pada fluktuasi permintaan yang tidak teratur dan pola non-linear. Nilai error yang dihasilkan relatif lebih tinggi dibandingkan model berbasis machine learning, terutama pada produk dengan volatilitas permintaan yang tinggi. Temuan ini menegaskan keterbatasan pendekatan tradisional dalam konteks data yang kompleks dan dinamis.

Selanjutnya, model machine learning seperti Random Forest dan XGBoost diuji untuk meningkatkan akurasi prediksi. Hasil menunjukkan bahwa kedua model ini mampu menangkap hubungan non-linear antar variabel dengan lebih baik. Random Forest memberikan performa stabil dengan variansi yang rendah, sementara XGBoost menghasilkan akurasi yang lebih tinggi pada sebagian besar produk. Model ini efektif dalam memanfaatkan fitur eksternal seperti promosi dan musim, yang terbukti memiliki pengaruh signifikan terhadap pola permintaan. Nilai MAE dan RMSE menunjukkan penurunan yang cukup signifikan dibandingkan model statistik, yang mengindikasikan peningkatan akurasi prediksi.

Pengujian lebih lanjut dilakukan menggunakan model deep learning berbasis LSTM dan BiLSTM. Model ini menunjukkan keunggulan dalam menangkap pola temporal

jangka panjang. LSTM mampu mengidentifikasi dependensi historis dalam data permintaan, sehingga menghasilkan prediksi yang lebih adaptif terhadap perubahan tren. BiLSTM memberikan hasil yang lebih baik dibandingkan LSTM karena mampu memproses informasi dari dua arah waktu, yaitu masa lalu dan masa depan dalam urutan data. Hal ini sangat relevan dalam konteks permintaan multi-produk yang memiliki pola fluktuatif dan saling terkait.

Meskipun model deep learning menunjukkan performa tinggi, terdapat tantangan dalam hal kompleksitas komputasi dan waktu pelatihan. Model ini membutuhkan sumber daya yang lebih besar dibandingkan metode lainnya. Oleh karena itu, penelitian ini mengembangkan pendekatan hybrid yang menggabungkan keunggulan model statistik, machine learning, dan deep learning. Hasil pengujian menunjukkan bahwa model hybrid memberikan performa terbaik secara keseluruhan. Model ini mampu menurunkan nilai error secara signifikan serta meningkatkan konsistensi prediksi pada berbagai jenis produk.

Pendekatan ensemble learning yang digunakan dalam penelitian ini juga memberikan kontribusi penting terhadap peningkatan performa model. Dengan menggabungkan beberapa model prediksi, sistem mampu mengurangi risiko overfitting dan meningkatkan generalisasi model. Hasil menunjukkan bahwa kombinasi XGBoost dan LSTM menghasilkan akurasi tertinggi dibandingkan kombinasi lainnya. Pendekatan ini mampu memanfaatkan kekuatan masing-masing model dalam menangkap pola data yang berbeda.

Selain itu, penerapan teknik clustering memberikan dampak positif dalam meningkatkan akurasi prediksi. Produk dikelompokkan berdasarkan karakteristik permintaan, seperti tingkat volatilitas dan pola musiman. Hasil menunjukkan bahwa model yang dilatih pada kelompok produk tertentu menghasilkan prediksi yang lebih akurat dibandingkan model yang dilatih secara keseluruhan. Teknik ini juga membantu mengurangi kompleksitas model dengan membagi data ke dalam kelompok yang lebih homogen.

Dalam konteks multi-produk, hasil penelitian menunjukkan adanya interdependensi antar produk yang signifikan. Produk substitusi dan komplementer memiliki pola

permintaan yang saling memengaruhi. Model yang mampu menangkap hubungan ini menunjukkan performa yang lebih baik dibandingkan model yang mengasumsikan independensi. Hal ini membuktikan bahwa pendekatan berbasis big data yang mempertimbangkan interaksi antar produk sangat penting dalam meningkatkan akurasi prediksi.

Integrasi hasil prediksi dengan sistem pengendalian persediaan menjadi bagian penting dalam penelitian ini. Hasil prediksi digunakan untuk menentukan nilai safety stock dan reorder point secara dinamis. Implementasi ini menunjukkan bahwa penggunaan model prediksi yang akurat mampu mengurangi tingkat overstock dan stockout secara signifikan. Perusahaan dapat mengoptimalkan tingkat persediaan tanpa mengorbankan tingkat pelayanan kepada pelanggan.

Analisis lebih lanjut menunjukkan bahwa penggunaan model berbasis Big Data Analytics mampu meningkatkan efisiensi operasional. Pengurangan biaya penyimpanan terjadi akibat penurunan kelebihan stok, sementara peningkatan ketersediaan produk berdampak positif terhadap kepuasan pelanggan. Selain itu, sistem yang dikembangkan mampu merespons perubahan permintaan secara lebih cepat, sehingga meningkatkan fleksibilitas dalam pengelolaan inventory.

Hasil evaluasi model menggunakan metrik MAE dan RMSE menunjukkan bahwa model hybrid berbasis ensemble memiliki nilai error terendah. Hal ini menunjukkan bahwa pendekatan integratif lebih efektif dibandingkan penggunaan model tunggal. Selain itu, hasil cross-validation menunjukkan bahwa model memiliki tingkat generalisasi yang baik dan tidak mengalami overfitting secara signifikan. Model juga mampu mempertahankan performa yang stabil ketika diuji menggunakan data real-time.

Dalam pembahasan teoritis, hasil penelitian ini sejalan dengan konsep Big Data Analytics yang menekankan pentingnya integrasi data dari berbagai sumber untuk menghasilkan insight yang lebih akurat. Pendekatan ini juga mendukung teori machine learning yang menyatakan bahwa model berbasis data-driven lebih efektif dalam menangani pola kompleks dibandingkan metode berbasis asumsi statistik.

Temuan ini memperkuat argumentasi bahwa kombinasi berbagai metode analitik dapat menghasilkan performa yang lebih optimal.

Dari perspektif manajemen operasi, penelitian ini memberikan kontribusi penting dalam pengembangan sistem pengendalian persediaan. Integrasi antara model prediksi dan kebijakan inventory menunjukkan bahwa keputusan operasional dapat ditingkatkan melalui pemanfaatan teknologi analitik. Pendekatan ini juga mendukung konsep prescriptive analytics yang menggabungkan prediksi dan optimasi dalam satu sistem terpadu.

Selain itu, penelitian ini menunjukkan bahwa teknologi big data memungkinkan pengambilan keputusan yang lebih cepat dan akurat. Kemampuan untuk memproses data secara real-time memberikan keunggulan kompetitif bagi perusahaan dalam menghadapi perubahan pasar. Hal ini sangat relevan dalam industri yang memiliki tingkat dinamika tinggi seperti retail dan e-commerce.

Namun, penelitian ini juga memiliki beberapa keterbatasan. Kompleksitas model yang tinggi memerlukan infrastruktur teknologi yang memadai. Tidak semua perusahaan memiliki kemampuan untuk mengimplementasikan sistem berbasis big data secara optimal. Selain itu, kualitas data menjadi faktor kritis yang memengaruhi performa model. Data yang tidak lengkap atau tidak akurat dapat menurunkan kualitas prediksi secara signifikan.

Keterbatasan lainnya terletak pada kebutuhan akan tenaga ahli dalam bidang data science dan machine learning. Pengembangan dan implementasi model membutuhkan keahlian khusus yang tidak selalu tersedia dalam organisasi. Oleh karena itu, diperlukan strategi pengembangan sumber daya manusia untuk mendukung implementasi teknologi ini.

Meskipun demikian, hasil penelitian ini menunjukkan potensi besar dari penggunaan Big Data Analytics dalam pengendalian persediaan multi-produk. Model yang dikembangkan mampu meningkatkan akurasi prediksi, mengurangi biaya operasional, serta meningkatkan tingkat pelayanan kepada pelanggan. Integrasi antara prediksi dan

kebijakan inventory menjadi kunci dalam menciptakan sistem yang lebih efisien dan adaptif.

Secara keseluruhan, penelitian ini membuktikan bahwa pendekatan hybrid berbasis big data merupakan solusi yang efektif untuk mengatasi kompleksitas prediksi permintaan dalam sistem multi-produk. Pendekatan ini tidak hanya meningkatkan performa prediksi, tetapi juga memberikan dampak nyata terhadap efisiensi operasional. Dengan demikian, penerapan model ini dapat menjadi strategi yang relevan bagi perusahaan dalam meningkatkan daya saing di era digital.

#### **D. Simpulan**

Penelitian ini menunjukkan bahwa penerapan model prediksi permintaan berbasis Big Data Analytics mampu meningkatkan akurasi peramalan dalam sistem pengendalian persediaan multi-produk. Integrasi data historis, perilaku konsumen, dan faktor eksternal terbukti memberikan informasi yang lebih komprehensif dalam menangkap pola permintaan yang kompleks. Pendekatan ini mampu mengatasi keterbatasan metode tradisional yang cenderung tidak adaptif terhadap dinamika pasar.

Hasil penelitian menegaskan bahwa penggunaan metode hybrid yang menggabungkan pendekatan statistik, machine learning, dan deep learning memberikan performa terbaik dibandingkan model tunggal. Kombinasi ini mampu menangkap pola linear dan non-linear secara simultan serta meningkatkan stabilitas prediksi. Selain itu, penerapan teknik ensemble learning dan clustering terbukti efektif dalam meningkatkan akurasi dan mengurangi risiko kesalahan prediksi, terutama dalam konteks multi-produk yang memiliki karakteristik permintaan beragam.

Integrasi model prediksi dengan kebijakan pengendalian persediaan memberikan dampak signifikan terhadap efisiensi operasional. Penentuan safety stock dan reorder point yang berbasis hasil prediksi memungkinkan perusahaan mengurangi risiko overstock dan stockout secara bersamaan. Hal ini berimplikasi langsung pada penurunan biaya penyimpanan serta peningkatan tingkat layanan kepada pelanggan.

Penelitian ini juga menunjukkan bahwa pendekatan berbasis big data memungkinkan sistem yang lebih responsif dan adaptif terhadap perubahan permintaan. Kemampuan untuk mengolah data secara real-time memberikan keunggulan dalam pengambilan keputusan yang lebih cepat dan tepat. Dengan demikian, model yang dikembangkan tidak hanya relevan secara teoritis, tetapi juga aplikatif dalam praktik industri.

Secara keseluruhan, penelitian ini memberikan kontribusi dalam pengembangan model prediksi permintaan yang terintegrasi dengan sistem pengendalian persediaan multi-produk. Pendekatan ini dapat menjadi solusi strategis bagi perusahaan dalam meningkatkan efisiensi operasional dan daya saing di era digital yang semakin kompleks.

## Daftar Pustaka

- Abualuroug, S., Alzubi, A., & Iyola, K. (2024). Inventory prediction using a modified multi-dimensional collaborative wrapped bi-directional long short-term memory model. *Applied Sciences*, *14*(13), 5817. <https://doi.org/10.3390/app14135817>
- Achakzai, M. K., Rehman, A., Ahmed, A., & Haider, S. O. (2025). The Role of Artificial Intelligence in Transforming Supply Chain Management: A Focus on Demand Forecasting and Inventory Optimization. *The Critical Review of Social Sciences Studies*, *3*(2), 622-637. <https://doi.org/10.59075/vs86kw78>
- Agarwal, R. (2025). Optimizing Inventory Forecasting with Big Data and Machine Learning Approaches. *Journal of Quantum Science and Technology*, *2*(4), 55-66. <https://doi.org/10.63345/jqst.v2i4.356>
- Ai, Z., Zhao, F., Hu, C., et al. (2024). Research on e-commerce product demand forecasting method based on ARIMA-SVR-PSO. *IEEE Conference Proceedings*, 778-783. <https://doi.org/10.1109/icirdc65564.2024.00145>
- Ankam, S. (2025). AI-driven demand forecasting in enterprise retail systems: Leveraging predictive analytics for enhanced supply chain. *IJSAT-International Journal on Science and Technology*, *16*(1). <https://doi.org/10.71097/ijst.v16.i1.2644>
- Baykal-G, M., & Erkip, N. (2011). Forecasting for inventory planning under correlated demand. In *Wiley Encyclopedia*

- of *Operations Research and Management Science*.  
<https://doi.org/10.1002/9780470400531.eorms0330>
- Chen, J. (2024). Advanced analytics for retail inventory and demand forecasting. *Transactions on Economics, Business and Management Research*, 10, 113-119.
- Duvaasi, V. (2025). How will strategic use of big data analytics transform retail supply chain management. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5005736>
- Elorza, M., Castellano, E., & Segura, S. (2025). Prediction of customer demand for perishable products in retail inventory management, using the hybrid prophet-XGBoost model during the post-COVID-19 period. *Applied Economics Letters*, 32(17), 2453-2459.  
<https://doi.org/10.1080/13504851.2024.2333995>
- Hu, L., & Han, W. (2024). Research on supply chain demand forecasting and dynamic adjustment model based on big data and artificial intelligence. *IEEE Conference Proceedings*, 153-159.  
<https://doi.org/10.1109/iist62526.2024.00100>
- Kalisetty, S. (2023). Harnessing Big Data and Deep Learning for Real-Time Demand Forecasting in Retail: A Scalable AI-Driven Approach. *American Online Journal of Science and Engineering*, 1(1). <https://doi.org/10.5281/zenodo.16418819>
- Li, X., Zheng, Y., Zhou, Z., & Zheng, Z. (2019). Demand prediction, predictive shipping, and product allocation for large-scale e-commerce. *Predictive Shipping, and Product Allocation for Large-Scale E-Commerce*.
- Luan, Y. (2024). Construction and Application Research of Beer Category Sales Forecasting Model Based on Big Data Analysis for Supermarket X. *International Journal of Emerging Technologies and Advanced Applications*, 1(10), 1-9. <https://doi.org/10.62677/ijetaa.2410128>
- Mohan, V., & Kurian, S. (2023). Product Demand Prediction. *Proceedings of the National Conference on Emerging Computer Applications (NCECA)*, 370–373. <https://doi.org/10.5281/zenodo.7956736>
- Murni, C. K., Choiri, A. F., & Rahmawati, F. D. (2025). Product Demand Forecasting in E-Commerce with Big Data Analytics: Personalization, Decision Making and Optimization. *Journal of Informatics Development*, 3(2), 1-6. <https://doi.org/10.30741/jid.v3i2.1548>

- Nagarajan, D., Bhuvaneshwari, T., & Suppiah, Y. (2025). Intelligent inventory prediction using random forest. *Edelweiss Applied Science and Technology*, 9(4).  
<https://doi.org/10.55214/25768484.v9i4.6383>
- Olatunji, A. O. (2025). Leveraging Data Science for Demand Forecasting and Inventory Management: A Comprehensive Review. *J. Basic Appl. Res. Int*, 31, 29-38.
- Schmidt, F. G., & Pibernik, R. (2025). Data-driven inventory control for large product portfolios: A practical application of prescriptive analytics. *European Journal of Operational Research*, 322(1), 254-269.  
<https://doi.org/10.1016/j.ejor.2024.10.012>
- Sekhar, C. (2022). Optimizing Retail Inventory Management with AI: A Predictive Approach to Demand Forecasting, Stock Optimization, and Automated Reordering. *European Journal of Advances in Engineering and Technology*, 9(11), 89-94. <https://doi.org/10.5281/zenodo.13325333>
- Seyedan, M., Mafakheri, F., & Wang, C. (2023). Order-up-to-level inventory optimization model using time-series demand forecasting with ensemble deep learning. *Supply Chain Analytics*, 3, 100024.  
<https://doi.org/10.1016/j.sca.2023.100024>
- Thi, H.-L., N. (2025). Harnessing the power of Big Data: transforming market prediction and supply chain optimization. *HPU2 Journal of Science: Natural Sciences and Technology*, 4(01), 71-83.  
<https://doi.org/10.56764/hpu2.jos.2025.4.01.71-83>
- Yang, Y. (2024). A Dynamic Export Product Sales Forecasting Model Based on Controllable Relevance Big Data for Cross-Border E-Commerce. *Applied Mathematics and Nonlinear Sciences*, 9(1), 10.  
<https://doi.org/10.2478/amns.2023.2.00049>