



PAPER – OPEN ACCESS

Literatur Review: Penggunaan Algoritma Machine Learning untuk Optimalisasi Rantai Pasokan

Author : Diomen Syahputra Manik, dkk
DOI : 10.32734/ee.v8i1.2671
Electronic ISSN : 2654-704X
Print ISSN : 2654-7031

Volume 8 Issue 1 – 2025 TALENTA Conference Series: Energy & Engineering (EE)



This work is licensed under a [Creative Commons Attribution-NoDerivatives 4.0 International License](https://creativecommons.org/licenses/by-nd/4.0/).
Published under licence by TALENTA Publisher, Universitas Sumatera Utara



Literatur Review: Penggunaan Algoritma Machine Learning untuk Optimalisasi Rantai Pasokan

Diomen Syahputra Manik*, Nazaruddin, Nismah Panjaitan

Program Studi Teknik Industri, Fakultas Teknik, Universitas Sumatera Utara, Jln. Dr. T. Mansyur No 9 Padang Bulan, Medan 20222, Indonesia

diomen.manik13@gmail.com, nazaruddin2@usu.ac.id, nismah.panjaitan@usu.ac.id

Abstrak

Dalam era bisnis yang semakin kompleks, optimalisasi rantai pasokan menjadi elemen kunci untuk meningkatkan efisiensi operasional, mengurangi biaya, dan menghadapi ketidakpastian pasar. Penelitian ini bertujuan mengkaji kontribusi teknologi machine learning (ML) dalam optimalisasi rantai pasok melalui pendekatan literature review terhadap 15 jurnal bereputasi internasional dalam sepuluh tahun terakhir (2015–2025). Hasil kajian menunjukkan bahwa ML berperan signifikan dalam tiga aspek utama: efisiensi operasional, akurasi prediksi permintaan, dan pengelolaan inventaris. Berbagai algoritma seperti Neural Networks, LSTM, XGBoost, SVM, Deep Q-Network, hingga metode meta-learning dan reinforcement learning digunakan untuk meningkatkan kecepatan respons, ketepatan prediksi tren pasar, serta pengelolaan stok berbasis data real-time. Selain itu, integrasi ML dengan teknologi seperti IoT dan RFID juga memperkuat efisiensi sistem distribusi dan deteksi anomali. Meskipun tantangan seperti keterbatasan data, infrastruktur teknologi, dan keamanan informasi masih menjadi hambatan, penelitian ini memperlihatkan bahwa penerapan ML menawarkan solusi strategis untuk membangun rantai pasok yang adaptif, cerdas, dan berkelanjutan di era digital. Temuan ini memberikan arah bagi penelitian dan implementasi lebih lanjut dalam pengembangan supply chain berbasis teknologi cerdas.

Kata Kunci: Machine Learning; Optimalisasi Rantai Pasok; Demand Forecasting; Inventory Management; Supply Chain Intelligence

Abstract

In an increasingly complex business era, supply chain optimization became a key element to improve operational efficiency, reduce costs, and address market uncertainties. This study aimed to examine the contribution of machine learning (ML) technology in optimizing the supply chain through a literature review approach on 15 internationally reputable journals over the past ten years (2015–2025). The review results showed that ML played a significant role in three main aspects: operational efficiency, demand forecasting accuracy, and inventory management. Various algorithms such as Neural Networks, LSTM, XGBoost, SVM, Deep Q-Network, as well as meta-learning and reinforcement learning methods, were used to enhance response speed, market trend prediction accuracy, and real-time data-based stock management. In addition, the integration of ML with technologies such as IoT and RFID also strengthened distribution system efficiency and anomaly detection. Although challenges such as data limitations, technological infrastructure, and information security remained obstacles, this study demonstrated that the application of ML offered strategic solutions to build an adaptive, intelligent, and sustainable supply chain in the digital era. These findings provided direction for further research and implementation in the development of technology-based intelligent supply chains.

Keywords: Machine Learning; Supply Chain Optimization; Demand Forecasting; Inventory Management; Supply Chain Intelligence

1. Introduction

Dalam lingkungan bisnis yang semakin kompleks dan dinamis, optimalisasi rantai pasokan menjadi faktor kunci dalam meningkatkan efisiensi operasional, mengurangi biaya, serta memastikan ketahanan terhadap ketidakpastian pasar [1]. Rantai pasokan yang efektif tidak hanya bergantung pada strategi tradisional, tetapi juga pada pemanfaatan teknologi cerdas untuk menganalisis data dan mempercepat pengambilan keputusan. Salah satu inovasi yang semakin banyak diadopsi adalah penggunaan algoritma machine learning (ML), yang mampu mengolah data dalam jumlah besar untuk mengidentifikasi pola, memprediksi tren, dan mengoptimalkan berbagai aspek dalam rantai pasokan [2].

Salah satu penerapan utama ML dalam rantai pasokan adalah demand forecasting atau peramalan permintaan. Berbagai algoritma, seperti random forest, gradient boosting, dan jaringan saraf tiruan (artificial neural networks), telah digunakan untuk meningkatkan akurasi prediksi dibandingkan metode tradisional seperti moving average atau regresi linier [3]. Dengan mempertimbangkan variabel eksternal, seperti tren pasar, perubahan cuaca, fluktuasi harga bahan baku, dan faktor makroekonomi, ML dapat membantu perusahaan menyesuaikan strategi produksi dan distribusi secara lebih adaptif. Prediksi permintaan yang lebih akurat mengurangi risiko kelebihan atau kekurangan stok, sehingga meningkatkan efisiensi rantai pasokan secara keseluruhan [4].

Selain peramalan permintaan, ML berperan penting dalam optimasi inventaris. Algoritma reinforcement learning dan support vector machines memungkinkan perusahaan mengelola stok secara lebih efektif dengan mempertimbangkan pola permintaan, waktu tunggu (lead time), serta biaya penyimpanan [5]. Dengan model prediktif berbasis ML, perusahaan dapat mengimplementasikan strategi manajemen stok yang lebih dinamis, seperti just-in-time inventory atau demand-driven supply chain, guna meminimalkan pemborosan dan mengoptimalkan penggunaan sumber daya [1]. Keunggulan ini sangat penting bagi industri dengan rantai pasokan yang kompleks, seperti manufaktur, farmasi, dan ritel [6].

Penerapan ML juga memberikan dampak besar dalam optimalisasi logistik dan distribusi. Algoritma seperti genetic algorithms, ant colony optimization, serta deep reinforcement learning digunakan untuk menemukan rute pengiriman paling efisien dengan mempertimbangkan variabel seperti kondisi lalu lintas, cuaca, dan kapasitas kendaraan [3]. Dalam skala global, perusahaan logistik memanfaatkan ML untuk mengoptimalkan pengelolaan gudang (warehouse management), pengalokasian sumber daya, serta penjadwalan pengiriman [7]. Dengan adanya sistem otomatis berbasis ML, perusahaan dapat mengurangi biaya bahan bakar, meningkatkan kecepatan distribusi, serta mengurangi emisi karbon, yang sejalan dengan praktik rantai pasokan berkelanjutan (sustainable supply chain) [2].

Selain optimasi operasional, ML juga memiliki peran strategis dalam manajemen risiko rantai pasokan. Model anomaly detection dan predictive analytics digunakan untuk mengidentifikasi potensi gangguan dalam rantai pasokan, seperti keterlambatan pengiriman, ketidakseimbangan pasokan dan permintaan, atau perubahan kebijakan perdagangan global [8]. Teknologi ini memungkinkan perusahaan merespons lebih cepat terhadap perubahan kondisi pasar dan mengembangkan strategi mitigasi risiko yang lebih efektif. Dalam beberapa kasus, ML juga digunakan untuk mendeteksi potensi penipuan dalam transaksi rantai pasokan, misalnya dengan mengidentifikasi pola anomali dalam data pembayaran dan transaksi keuangan [4].

Meskipun manfaat ML dalam optimalisasi rantai pasokan sangat besar, implementasinya masih menghadapi sejumlah tantangan. Salah satu kendala utama adalah ketersediaan data yang berkualitas tinggi dan terintegrasi [3]. Model ML sangat bergantung pada data historis yang akurat dan representatif, namun dalam praktiknya, banyak perusahaan masih menghadapi kesulitan dalam mengumpulkan, mengelola, dan menggabungkan data dari berbagai sumber dalam rantai pasokan [9]. Selain itu, kompleksitas algoritma ML, terutama yang berbasis deep learning, dapat menjadi penghalang bagi perusahaan yang tidak memiliki infrastruktur teknologi dan tenaga ahli yang memadai. Isu

lain yang juga perlu diperhatikan adalah keamanan data dan privasi, terutama dalam rantai pasokan global yang melibatkan banyak entitas dengan kepentingan berbeda [10].

Literatur review ini bertujuan untuk mengkaji secara mendalam bagaimana machine learning telah digunakan dalam optimalisasi rantai pasokan, mulai dari peramalan permintaan, pengelolaan inventaris, optimasi distribusi, hingga manajemen risiko. Kajian ini juga akan mengeksplorasi tantangan dalam implementasi ML, serta solusi potensial untuk mengatasi hambatan tersebut. Selain itu, akan dibahas pula tren terbaru dan arah penelitian masa depan dalam penerapan ML di rantai pasokan, termasuk integrasi dengan teknologi lain seperti Internet of Things (IoT) dan blockchain [11]. Dengan memahami perkembangan terkini dalam bidang ini, diharapkan dapat diperoleh wawasan yang lebih luas mengenai dampak dan prospek machine learning dalam meningkatkan efisiensi dan ketahanan rantai pasokan di era digital.

2. Research Methods

Penelitian ini menggunakan pendekatan literature review untuk mengkaji penerapan machine learning dalam optimalisasi rantai pasokan. Metode ini dipilih karena memungkinkan peneliti untuk mengidentifikasi, menganalisis, dan mensintesis berbagai penelitian terdahulu guna memperoleh pemahaman yang komprehensif mengenai perkembangan teknologi machine learning dalam supply chain management [12].

Data yang digunakan dalam penelitian ini bersumber dari jurnal-jurnal ilmiah, prosiding konferensi, dan artikel penelitian yang dipublikasikan dalam database bereputasi seperti Scopus, Web of Science (WoS), IEEE Xplore, SpringerLink, Elsevier (ScienceDirect), dan Google Scholar. Penelusuran literatur dilakukan dengan menggunakan kata kunci seperti “Machine Learning in Supply Chain Management”, “Demand Forecasting using Machine Learning”, “Inventory Optimization with AI”, “Neural Networks for Supply Chain Optimization”, “Deep Learning in Logistics and Supply Chain”, serta “Predictive Analytics for Supply Chain Management”. Hanya artikel yang dipublikasikan dalam 10 tahun terakhir (2015-2025) dan memiliki faktor dampak tinggi dalam bidang supply chain dan artificial intelligence yang dipertimbangkan dalam review ini.

Untuk memastikan relevansi dan kualitas penelitian yang ditinjau, digunakan beberapa kriteria inklusi dan eksklusi. Kriteria inklusi meliputi jurnal internasional yang terindeks Scopus Q1-Q4 atau WoS, studi yang membahas penerapan machine learning dalam optimalisasi rantai pasokan, penelitian yang menggunakan metode kuantitatif atau eksperimen berbasis data dalam supply chain, serta artikel yang dipublikasikan dalam bahasa Inggris atau bahasa Indonesia. Sementara itu, kriteria eksklusi meliputi artikel yang tidak berfokus pada penerapan machine learning dalam supply chain, studi yang bersifat teoritis tanpa implementasi praktis atau uji coba berbasis data, penelitian yang lebih berfokus pada aspek ekonomi atau manajerial tanpa keterkaitan dengan algoritma ML, serta artikel dengan metodologi yang tidak jelas atau tidak memiliki validasi empiris [12].

3. Results and Discussion

Sistem *machine learning* dalam rantai pasokan membantu dalam mengoptimalkan efisiensi operasional dan meningkatkan akurasi prediksi permintaan. Dengan demikian, teknologi ini memungkinkan perusahaan untuk mengurangi risiko kelebihan atau kekurangan stok serta meningkatkan ketepatan dalam distribusi barang. Berdasarkan penelaahan kajian pustaka yang telah dilakukan sesuai dengan kriteria inklusi dan eksklusi yang ditetapkan, diperoleh sebanyak 15 referensi utama dari jurnal dan konferensi bereputasi. Ringkasan hasil tinjauan literatur mengenai penerapan *machine learning* dalam rantai pasokan disajikan pada Tabel 1.

Tabel 1. Mapping Literatur Jurnal

No.	Paper identify	Metode ML yang digunakan	Fokus Penelitian	Result
1.	J. A. C. Soto, et al (2019) [13]	- Multilayer Perceptron (MLP) - Learning Vector Quantization (LVQ) - Probabilistic Deterministic Timed Automata (PDTA)	- Mengembangkan kerangka kerja pembelajaran mesin online untuk mendeteksi kegagalan produk secara real-time di lingkungan manufaktur Industry 4.0. - Mengintegrasikan data log proses produksi untuk pelatihan model secara incremental dan prediksi waktu nyata.	- Kerangka kerja yang diusulkan berhasil mendeteksi kegagalan produk secara real-time tanpa mengganggu proses produksi fisik. - Sistem adaptif mampu menyesuaikan diri dengan perubahan spesifikasi produk dalam proses manufaktur mass-customization. - Mengurangi limbah produksi dengan mencegah penambahan komponen pada produk yang gagal. - Meningkatkan efisiensi produksi melalui pengurangan upaya penanganan produk gagal dan pengurangan biaya inspeksi tradisional.
2.	H. J. Wahedi, et al (2023) [14]	Peramalan: - Artificial Neural Network (ANN) - Long Short-Term Memory (LSTM) - Support Vector Regression (SVR) - Random Forest (RF) - Wavelet-ANN (W-ANN) - Wavelet-LSTM (W-LSTM) Manajemen Inventaris: - Q-learning - Deep Q Network (DQN)	- Mengevaluasi algoritma berbasis data untuk peramalan dan perencanaan inventaris di UKM (Usaha Kecil Menengah). - Memvalidasi bagaimana algoritma tersebut dapat memberikan manfaat bagi UKM. - Menerapkan algoritma reinforcement learning (Q-Learning) untuk masalah manajemen inventaris.	- Model ML prediktif memiliki kinerja yang lebih unggul dibandingkan dengan pendekatan peramalan statistik tradisional, tetapi tidak selalu jika berfokus pada KPI industri. - Q-learning menghasilkan hasil ekonomi yang lebih baik dalam hal perencanaan inventaris. - Model yang diusulkan dapat berfungsi sebagai perpanjangan dari sistem ERP modern dengan menawarkan pendekatan berbasis data untuk pengambilan keputusan perencanaan permintaan dan pasokan.
3.	S. Anitha, et al (2023) [15]	- K-Means Clustering - Decision Tree Classification	- Mengembangkan model peramalan permintaan produk fashion baru dengan machine learning untuk menganalisis preferensi pelanggan. - Memanfaatkan data fitting room untuk memahami preferensi dan membuat profil pelanggan. - Meningkatkan akurasi peramalan guna membantu peritel mengelola inventaris dan menghindari kelebihan stok.	- Model yang diusulkan memungkinkan peritel untuk menyimpan produk yang sesuai dengan preferensi pelanggan. - Pendekatan peramalan permintaan ini membantu meminimalkan kelebihan inventaris. - Analisis data fitting room memberikan pemahaman yang lebih komprehensif tentang preferensi pelanggan dibandingkan hanya menggunakan data penjualan.
4.	K. Namira, et al (2021) [16]	- ARIMA-NARNN: Digunakan untuk peramalan harga bahan baku (base oil)	- Mengembangkan model yang menggabungkan time series, machine learning, dan optimisasi	- Alat pendukung keputusan (decision support tool) yang dapat memberikan rekomendasi (Beli, Jual, atau Tahan) dan

No.	Paper identify	Metode ML yang digunakan	Fokus Penelitian	Result
		berdasarkan data historis. - XGBoost: Digunakan untuk peramalan permintaan. - Combinatorial Optimization: Digunakan untuk menentukan keputusan terbaik (Beli, Jual, atau Tahan).	kombinatorial untuk mengidentifikasi peluang pembelian stok lebih murah dan penjualan stok yang tidak terpakai. - Mengintegrasikan peramalan harga dan permintaan dalam algoritma optimisasi kombinatorial untuk mendukung pengambilan keputusan.	kuantitas optimal untuk manajemen inventaris dinamis. - Peningkatan keuntungan dengan mengoptimalkan waktu pembelian dan penjualan stok. - Memastikan ketersediaan stok untuk produksi sambil meminimalkan biaya penyimpanan.
5.	Z. Xu, et al (2024) [17]	- Feature-based First-Order Model-Agnostic Meta-Learning (F-FOMAML) - Graph Neural Networks (GNNs)	- Mengembangkan pendekatan prediksi permintaan puncak menggunakan data proxy dari periode non-puncak. - Memformulasikan prediksi sebagai masalah meta-learning dengan algoritma F-FOMAML. - Menunjukkan bahwa penggunaan metadata tugas meningkatkan generalisasi model.	- Algoritma F-FOMAML menunjukkan peningkatan yang signifikan dalam akurasi prediksi permintaan, mengurangi Mean Absolute Error (MAE) sebesar 26.24% pada dataset mesin penjual otomatis internal dan sebesar 1.04% pada dataset JD.com yang dapat diakses publik. - Model ini secara konsisten mengungguli metode peramalan yang ada dalam nilai MAE prediksi sebesar 8.7% pada dataset mesin penjual otomatis dan sebesar 1.04% pada dataset JD.com menggunakan fitur yang dibangun berdasarkan pengetahuan domain.
6.	X. Yao, et al (2020) [18]	- Functional Clustering (funHDDC): Metode machine learning untuk mengelompokkan 30 provinsi di China ke dalam 4 klaster berdasarkan pola kinerja efisiensi hijau mereka.	- Menganalisis kinerja efisiensi hijau industri logistik di 30 provinsi di China dari tahun 2008 hingga 2017. - Mengidentifikasi perbedaan dan persamaan dalam pola kinerja efisiensi hijau antar kelompok provinsi yang berbeda. - Mengeksplorasi faktor-faktor pendorong perubahan dinamis dalam efisiensi hijau melalui metode dekomposisi.	- Tingkat efisiensi hijau berkorelasi erat dengan lokasi geografis. Wilayah timur umumnya memiliki efisiensi hijau lebih tinggi daripada wilayah barat. - Kinerja efisiensi hijau di beberapa wilayah dengan tingkat ekonomi tinggi (seperti Beijing dan Shanghai) tidak memuaskan. - Efek inovasi industri logistik China adalah yang paling jelas, tetapi perubahan efisiensi masih perlu ditingkatkan, dan kepemimpinan teknis harus diperkuat.
7.	K. B. Praveen, et al (2020) [19]	- XGBoost Regression: Digunakan untuk melakukan prediksi permintaan.	- Mengembangkan sistem manajemen inventaris berbasis machine learning untuk membantu UKM meningkatkan penjualan dan memprediksi permintaan produk. - Mengatasi tantangan inventaris dengan mengurangi out-of-stock	- Model XGBoost menunjukkan peningkatan efisiensi dengan penambahan data mingguan baru untuk pelatihan. - Model mampu memprediksi nilai permintaan untuk minggu-minggu mendatang, membantu pemilik toko dalam manajemen inventaris yang efisien.

No.	Paper identify	Metode ML yang digunakan	Fokus Penelitian	Result
			dan biaya melalui perencanaan yang lebih baik. - Memanfaatkan data terstruktur untuk meningkatkan akurasi peramalan.	- Tabel RMSE menunjukkan fluktuasi nilai RMSE seiring dengan penambahan data mingguan, mengindikasikan pentingnya data yang berkelanjutan untuk meningkatkan akurasi model.
8.	O.Olaleye (2024) [20]	- CatBoost: Digunakan untuk peramalan lead time dan permintaan. - Extreme Gradient Boosting (XGBoost): Digunakan untuk peramalan lead time dan permintaan. - Random Forest: Digunakan untuk peramalan lead time dan permintaan.	- Mengembangkan metodologi berbasis data untuk menentukan dimensi safety stock dan mengoptimalkan inventaris bahan baku di Amgen. - Mengatasi masalah tingginya inventaris bahan baku akibat kompleksitas proses biomanufaktur dan ketidakpastian lead time serta permintaan. - Mengembangkan kerangka segmentasi untuk alokasi tingkat layanan berdasarkan toleransi risiko material.	- Hasil validasi pada sampel material menunjukkan potensi pengurangan inventaris lebih dari 25% sambil tetap mencegah stockout. - Potensi penghematan jutaan dolar dalam biaya pengadaan dan penyimpanan. - Usulan rencana implementasi bertahap untuk memastikan transisi yang mulus ke pendekatan berbasis data baru dalam organisasi.
9.	J. Feizabadi (2022) [21]	- ARIMAX (Autoregressive Integrated Moving Average dengan variabel eksogen) - Neural Networks	Mengembangkan metode hybrid berbasis ML untuk peramalan permintaan produk fungsional di industri baja	- Peningkatan kinerja rantai pasok yang signifikan secara statistik dibandingkan metode tradisional - Metode hybrid menggabungkan data deret waktu dan indikator eksogen berhasil dikembangkan - Fokus pada akurasi peramalan, perputaran inventori, dan siklus konversi kas
10.	F. Lolli, et al (2018) [22]	- Support Vector Machines (SVM) dengan Gaussian Kernel - Deep Neural Networks (DNN)	Mengembangkan pendekatan klasifikasi inventaris berbasis multi-kriteria menggunakan machine learning untuk permintaan intermiten.	- Akurasi tinggi dalam klasifikasi item inventaris berdasarkan kriteria multi-kriteria. - Mengurangi upaya simulasi melalui pembelajaran dari data sampel. - Metode ini fleksibel untuk permintaan intermiten maupun non-intermiten.
11.	N. Ali, et al (2021) [23]	- Support Vector Machine (SVM)	Mengembangkan model simulasi kolaborasi informasi rantai pasok menggunakan teknik machine learning untuk meningkatkan efisiensi sistem.	- Akurasi tinggi diperoleh: 98,99% (pelatihan), 98,91% (pengujian), dan 98,92% (validasi). - Model ini mampu merevolusi pola kolaborasi informasi rantai pasok dan memberikan keunggulan kompetitif yang signifikan bagi keberlanjutan bisnis.
12.	S. Paul, et al (2019) [24]	Tidak secara eksplisit menggunakan metode ML, tetapi membahas implementasi RFID dan IoT	Membahas pengembangan sistem manajemen inventaris cerdas berbasis IoT untuk meningkatkan efisiensi dan akurasi	- Sistem berbasis IoT memberikan keunggulan dibandingkan metode tradisional karena memungkinkan pelacakan dan pelaporan aset secara otomatis.

<i>No.</i>	<i>Paper identify</i>	<i>Metode ML yang digunakan</i>	<i>Fokus Penelitian</i>	<i>Result</i>
			dibandingkan dengan model manajemen inventaris tradisional.	- Implementasi RFID meningkatkan efisiensi dan mengurangi kemungkinan kesalahan manusia. - Sistem ini menggunakan RFID untuk mengidentifikasi dan melacak item inventaris, serta teknologi IoT untuk menghubungkan perangkat dan memproses data secara real-time.
13.	H. Meisheri, et al (2020) [25]	- Advantage Actor Critic (A2C) - Deep Q-Network (DQN) dengan quantised action spaces	Mengevaluasi penerapan reinforcement learning (RL) untuk manajemen inventaris multi-produk dalam rantai pasok, dengan mempertimbangkan kendala realistis seperti kapasitas bersama dan perubahan jumlah produk secara dinamis.	- Pendekatan RL (A2C dan DQN) menunjukkan kinerja yang lebih baik dibandingkan algoritma baseline lainnya pada skala 100 hingga 220 produk. - Mampu melakukan transfer learning tanpa pelatihan ulang ketika jumlah produk berubah. - Formulasi RL dapat diparalelkan untuk pengambilan keputusan yang lebih efisien. - Mempertimbangkan tujuan bisnis yang realistis seperti ketersediaan seluruh rangkaian produk dan minimisasi pemborosan.
14.	C. Deng, et al (2021) [26]	- Deep Learning (Long Short-Term Memory, LSTM) - Convolutional Neural Network (CNN) - Hybrid LSTM-CNN - Reinforcement Learning untuk optimasi inventori	- Prediksi permintaan produk dengan menggunakan data historis penjualan. - Optimasi pengelolaan stok agar sesuai dengan tren pasar. - Penggunaan teknik deep learning untuk meningkatkan akurasi prediksi dibandingkan metode tradisional. - Integrasi model hybrid untuk memanfaatkan keunggulan CNN dalam ekstraksi fitur dan LSTM dalam menangkap pola temporal.	- Model LSTM-CNN menunjukkan performa lebih baik dibandingkan metode statistik konvensional dalam peramalan permintaan. - Akurasi prediksi meningkat secara signifikan dibandingkan metode klasik seperti ARIMA. - Sistem yang dikembangkan mampu mengoptimalkan pengelolaan inventori dengan mengurangi kelebihan stok dan menghindari kekurangan pasokan. - Implementasi reinforcement learning membantu dalam penyesuaian kebijakan stok secara dinamis berdasarkan permintaan yang diprediksi.
15.	H. Lin, et al (2022) [27]	- Random Forest - Support Vector Machine (SVM) - Artificial Neural Network (ANN) - Long Short-Term Memory (LSTM) - Reinforcement Learning untuk optimasi inventori	- Penggunaan data historis penjualan dan faktor eksternal untuk meningkatkan prediksi permintaan. - Pengembangan model machine learning yang dapat menangani pola musiman dan tren dalam rantai pasok. - Implementasi reinforcement learning	- Model LSTM menunjukkan akurasi prediksi yang lebih tinggi dibandingkan metode tradisional seperti ARIMA. - Penggunaan Random Forest dan SVM membantu dalam memahami faktor yang paling berpengaruh terhadap permintaan. - Implementasi reinforcement learning meningkatkan efisiensi inventori dengan mengurangi kelebihan dan kekurangan stok secara signifikan. - Sistem yang dikembangkan berhasil mengoptimalkan strategi distribusi

No.	Paper identify	Metode ML yang digunakan	Fokus Penelitian	Result
			untuk menyesuaikan stok secara dinamis.	berdasarkan prediksi permintaan yang lebih akurat.

Untuk memperoleh pemahaman yang lebih komprehensif mengenai kontribusi machine learning dalam optimalisasi rantai pasok, dilakukan kajian literatur dari berbagai penelitian sebelumnya. Kajian ini disusun berdasarkan hasil identifikasi dan analisis terhadap sejumlah artikel ilmiah yang merepresentasikan implementasi metode machine learning dalam berbagai aspek rantai pasok. Fokus utama dalam kajian ini terbagi ke dalam tiga kategori, yaitu: efisiensi rantai pasok, akurasi prediksi permintaan, dan pengelolaan inventaris. Masing-masing aspek dikaji berdasarkan pendekatan yang digunakan, hasil yang dicapai, serta relevansi penerapannya terhadap peningkatan kinerja rantai pasok secara keseluruhan. Berikut uraian hasil kajian tersebut.

3.1. Efisiensi Rantai Pasok

Banyak penelitian menekankan peran machine learning dalam meningkatkan efisiensi operasional dalam rantai pasok. Soto et al. (2019) menunjukkan bahwa penggunaan MLP, LVQ, dan PDTA memungkinkan deteksi kegagalan produk secara real-time tanpa mengganggu proses produksi fisik, yang secara signifikan meningkatkan efisiensi dan mengurangi biaya inspeksi serta limbah produksi.

Wahedi et al. (2023) menekankan bahwa Q-learning dapat meningkatkan hasil ekonomi dalam perencanaan inventaris, sementara Meisheri et al. (2020) menunjukkan efektivitas pendekatan reinforcement learning (A2C dan DQN) untuk manajemen multi-produk, mempercepat pengambilan keputusan dan mempertahankan efisiensi sistem di bawah berbagai skenario permintaan dan kapasitas.

Paul et al. (2019) membuktikan bahwa integrasi IoT dan RFID dalam sistem inventaris memberikan efisiensi lebih tinggi melalui pelacakan otomatis. Deng et al. (2021) dan Lin et al. (2022) menambahkan bahwa kombinasi deep learning dan reinforcement learning mengoptimalkan strategi distribusi dengan respons adaptif terhadap tren pasar.

3.2. Akurasi Prediksi Permintaan

Akurasi peramalan menjadi aspek paling dominan dalam kajian literatur. Xu et al. (2024) mengembangkan metode F-FOMAML yang mampu meningkatkan akurasi hingga 26.24% pada dataset internal, dengan mempertimbangkan metadata spesifik tugas dan pendekatan meta-learning. Namira et al. (2021) juga menunjukkan bahwa penggabungan ARIMA-NARNN dan XGBoost dapat secara efektif memperkirakan harga bahan baku dan permintaan, mendukung keputusan pembelian dan penjualan stok.

Feizabadi (2022) mengembangkan model hybrid (ARIMAX + Neural Network) yang menunjukkan keunggulan signifikan dibanding metode tradisional dalam peramalan produk industri baja. Sementara itu, Anitha et al. (2023) memanfaatkan data fitting room untuk membangun model prediktif berbasis preferensi pelanggan yang lebih akurat dibandingkan hanya menggunakan data penjualan.

Model berbasis LSTM dan hybrid LSTM-CNN (Deng et al., 2021; Lin et al., 2022) juga terbukti lebih unggul dibanding ARIMA dalam menangkap pola musiman dan temporal dalam prediksi permintaan. Praveen et al. (2020) dan Yao et al. (2020) menunjukkan bahwa pendekatan XGBoost dan clustering dapat meningkatkan pemahaman terhadap pola regional maupun mingguan, yang meningkatkan akurasi prediksi secara kontekstual.

3.3. Pengelolaan Inventaris

Dalam aspek pengelolaan inventaris, penelitian oleh Olaleye (2024) dan Lolli et al. (2018) menunjukkan pendekatan berbasis klasifikasi dan prediksi probabilistik dapat mengurangi stok berlebih dan meningkatkan perencanaan kebutuhan stok. Metode seperti CatBoost dan simulasi stokastik berhasil menyesuaikan safety stock berdasarkan toleransi risiko material, yang dalam studi kasus Amgen, menghasilkan potensi penghematan biaya hingga jutaan dolar.

Hasil serupa ditemukan oleh Ali et al. (2021) yang menggunakan SVM untuk simulasi kolaboratif dalam rantai pasok yang menghasilkan akurasi sangat tinggi dan mengoptimalkan alur informasi inventaris. Di sisi lain, pendekatan deep reinforcement learning (Deng et al., 2021; Lin et al., 2022; Meisheri et al., 2020) memperlihatkan kemampuan adaptasi dalam menyesuaikan kebijakan inventaris terhadap kondisi permintaan secara real-time.

Tabel 2. Temuan Utama Berdasarkan Aspek dalam Kajian Literatur

Aspek	Temuan Utama
Efisiensi Rantai Pasok	Peningkatan respons real-time, pengurangan limbah, dan pengambilan keputusan cepat berkat RL, IoT, dan sistem cerdas.
Akurasi Prediksi	Model hybrid (LSTM, XGBoost, ARIMAX, Meta-Learning) unggul dalam memahami pola tren dan musiman dibanding metode klasik.
Pengelolaan Inventaris	Stok dapat dioptimalkan melalui klasifikasi berbasis ML, segmentasi risiko, dan kebijakan adaptif dengan RL.

4. Conclusion

Penelitian ini menyimpulkan bahwa penerapan teknologi machine learning dalam manajemen rantai pasok telah menunjukkan dampak yang signifikan terhadap peningkatan efisiensi operasional, akurasi prediksi permintaan, serta pengelolaan inventaris yang lebih adaptif dan cerdas. Melalui metode literature review terhadap 15 jurnal dan prosiding bereputasi internasional dalam 10 tahun terakhir, ditemukan bahwa algoritma seperti Neural Networks, LSTM, XGBoost, SVM, Deep Q-Network, hingga pendekatan meta-learning dan reinforcement learning digunakan secara luas dalam berbagai aspek rantai pasok, mulai dari peramalan permintaan, optimasi inventaris, pengurangan limbah produksi, hingga pengambilan keputusan strategis.

Beberapa model berhasil mengintegrasikan data historis, tren musiman, serta preferensi pelanggan untuk meningkatkan ketepatan sistem peramalan dan perencanaan logistik. Penerapan algoritma seperti Q-learning, CatBoost, dan GNNs juga memperlihatkan kemampuan dalam menangani ketidakpastian pada permintaan dan waktu pengiriman (lead time), sekaligus memungkinkan penghematan biaya penyimpanan dan pengadaan yang signifikan.

Secara keseluruhan, machine learning tidak hanya menawarkan peningkatan teknis dalam pemrosesan data besar (big data) dan otomatisasi proses pengambilan keputusan, tetapi juga memberikan nilai strategis bagi perusahaan dalam mencapai efisiensi, kecepatan respon pasar, dan keunggulan kompetitif dalam era digital supply chain. Namun demikian, implementasi optimal masih membutuhkan dukungan data berkualitas, integrasi sistem yang baik, serta pemahaman mendalam terhadap konteks bisnis yang sedang dihadapi.

References

- [1] L. Saptaria and N. Nurhidayati, "Analisis peramalan permintaan produk nata de coco untuk mendukung perencanaan dan pengendalian produksi dalam supply chain dengan model cpfr," *J. Nasant. Apl. Manaj. Bisnis*, vol. 2, no. 2, pp. 130–141, 2017.
- [2] R. Toorajipour, V. Sohrabpour, A. Nazarpour, P. Oghazi, and M. Fischl, "Artificial intelligence in supply chain management: A systematic literature review," *J. Bus. Res.*, vol. 122, no. September 2020, pp. 502–517, 2021, doi: 10.1016/j.jbusres.2020.09.009.
- [3] M. A. Rayadin, M. Musaruddin, R. A. Saputra, and I. Isnawaty, "Implementasi Ensemble Learning Metode XGBoost dan Random Forest untuk Prediksi Waktu Penggantian Baterai Aki," *BIOS J. Teknol. Inf. dan Rekayasa Komput.*, vol. 5, no. 2, pp. 111–119, 2024.
- [4] M. Pasaribu and A. Widjaja, *Artificial Intelligence: Perspektif Manajemen Strategis*. Jakarta: Kepustakaan Populer Gramedia, 2022.
- [5] D. A. Wuttke, C. Blome, and M. Henke, "Focusing the financial flow of supply chains: An empirical investigation of financial supply chain management," *Int. J. Prod. Econ.*, vol. 145, no. 2, pp. 773–789, 2013, doi: 10.1016/j.ijpe.2013.05.031.
- [6] I. Zaenuddin and A. B. Riyan, "Perkembangan Kecerdasan Buatan (AI) Dan Dampaknya Pada Dunia Teknologi," *Jitu J. Inform. Utama*, vol. 2, no. 2, pp. 128–153, 2024.

- [7] S. Wardah, N. Nurhasanah, and W. Sudarwati, "Integration models of demand forecasting and inventory control for coconut sugar using the ARIMA and EOQ modification methods," *J. Sist. dan Manaj. Ind.*, vol. 7, no. 2, pp. 127–138, 2023, doi: 10.30656/jsmi.v7i2.6500.
- [8] B. Karimi, M. Ghare Hassanlu, and A. H. Niknamfar, "An integrated production-distribution planning with a routing problem and transportation cost discount in a supply chain," *Assem. Autom.*, vol. 39, no. 5, pp. 783–802, 2019, doi: 10.1108/AA-10-2017-127.
- [9] A. J. van Weele, *Purchasing and Supply Chain Management*. 2008. doi: 10.1002/9783527622771.ch1.
- [10] N. Fajrah, M. R. Ridho, and S. Zetli, "Studi Simulasi untuk Optimasi Rantai Pasok IKM Makanan dengan Pendekatan Deep Reinforcement Learning," pp. 8–15, 2025.
- [11] N. Susi, S. Sugiana, and B. Musty, "Analisis Data Sistem Informasi Monitoring Marketing; Tools Pengambilan Keputusan Strategic," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 12, no. 2, pp. 696–708, 2023.
- [12] M. Mohamed-Ilias, B. Loubna, and B. Abdelaziz, *Machine Learning in Supply Chain Management: A Systematic Literature Review*, vol. 9, no. 4. 2022. doi: 10.22034/ijssom.2021.109189.2279.
- [13] J. A. Carvajal Soto, F. Tavakolizadeh, and D. Gyulai, "An online machine learning framework for early detection of product failures in an Industry 4.0 context," *Int. J. Comput. Integr. Manuf.*, vol. 32, no. 4–5, pp. 452–465, 2019, doi: 10.1080/0951192X.2019.1571238.
- [14] H. J. Wahedi, M. Heltoft, G. J. Christophersen, T. Severinsen, S. Saha, and I. E. Nielsen, "Forecasting and Inventory Planning: An Empirical Investigation of Classical and Machine Learning Approaches for Svanehøj's Future Software Consolidation," *Appl. Sci.*, vol. 13, no. 15, pp. 1–21, 2023, doi: 10.3390/app13158581.
- [15] S. Anitha and R. Neelakandan, "A Demand Forecasting Model Leveraging Machine Learning to Decode Customer Preferences for New Fashion Products," *Complexity*, vol. 2024, 2024, doi: 10.1155/2024/8425058.
- [16] K. Namir, H. Labriji, and E. H. Ben Lahmar, "Decision Support Tool for Dynamic Inventory Management using Machine Learning, Time Series and Combinatorial Optimization," *Procedia Comput. Sci.*, vol. 198, no. 2021, pp. 423–428, 2021, doi: 10.1016/j.procs.2021.12.264.
- [17] Z. Xu, L. Zhang, S. Yang, and N. Jiang, "Peak Period Demand Forecasting with Proxy Data: GNN-Enhanced Meta-Learning," *Proc. - 2024 IEEE Winter Conf. Appl. Comput. Vis. Work. WACVW 2024*, pp. 726–735, 2024, doi: 10.1109/WACVW60836.2024.00129.
- [18] X. Yao, Y. Cheng, L. Zhou, and M. Song, "Green efficiency performance analysis of the logistics industry in China: based on a kind of machine learning methods," *Ann. Oper. Res.*, vol. 308, no. 1–2, pp. 727–752, 2022, doi: 10.1007/s10479-020-03763-w.
- [19] K. B. Praveen, P. Kumar, J. Prateek, G. Pragathi, and J. Madhuri, "Inventory management using machine learning," *Int. J. Eng. Res. Technol.*, vol. 9, no. 6, pp. 866–869, 2020.
- [20] O. Olaleye, D. S. Boning, N. Golrezaei, L. A. Kolodziejski, and M. Herson, "Machine Learning and Stochastic Simulation for Inventory Management," 2024.
- [21] J. Feizabadi, "Machine learning demand forecasting and supply chain performance," *Int. J. Logist. Res. Appl.*, vol. 25, no. 2, pp. 119–142, 2022, doi: 10.1080/13675567.2020.1803246.
- [22] F. Lolli, E. Balugani, A. Ishizaka, R. Gamberini, B. Rimini, and A. Regattieri, "Machine learning for multi-criteria inventory classification applied to intermittent demand," *Prod. Plan. Control*, vol. 30, no. 1, pp. 76–89, 2019, doi: 10.1080/09537287.2018.1525506.
- [23] N. Ali *et al.*, "Modelling supply chain information collaboration empowered with machine learning technique," *Intell. Autom. Soft Comput.*, vol. 30, no. 1, pp. 243–257, 2021, doi: 10.32604/iasc.2021.018983.
- [24] P. Souvik, C. Atreyee, and G. Digbijay, "Study of smart inventory management system based on the internet of things (IOT)," *IJRTBT Int. J. Recent Trends Bus. Tour.*, vol. 3, no. 3, pp. 27–34, 2019, [Online]. Available: <https://ejournal.lucp.net/index.php/ijrtbt/article/view/749/662>
- [25] H. Meisheri, V. Baniwal, N. N. Sultana, H. Khadilkar, and B. Ravindran, "Using Reinforcement Learning for a Large Variable-Dimensional Inventory Management Problem," *ALA 2020 - Adapt. Learn. Agents Work. AAMAS 2020*, 2020.
- [26] C. Deng and Y. Liu, "A Deep Learning-Based Inventory Management and Demand Prediction Optimization Method for Anomaly Detection," *Wirel. Commun. Mob. Comput.*, vol. 1, p. 14, 2021, doi: 10.1155/2021/9969357.
- [27] H. Lin, J. Lin, and F. Wang, "An innovative machine learning model for supply chain management," *J. Innov. Knowl.*, vol. 7, no. 4, 2022, doi: 10.1016/j.jik.2022.100276.