

PEMODELAN HYBRID SUPPORT VECTOR MACHINE DAN K-NEAREST NEIGBORS UNTUK PERAMALAN PERMINTAAN SUKU CADANG OTOMOTIF: PENDEKATAN MACHINE LEARNING TERHADAP DATA FLUKTUATIF

Oleh :

Benny Martha Dinata¹⁾, Eka Ardhiyanto²⁾

^{1,2} FTII, Unisbank Semarang

¹email: bennymartha0002@mhs.unisbank.ac.id

²email: ekaardhiyanto@edu.unisbank.ac.id

Informasi Artikel

Riwayat Artikel :

Submit, 8 Oktober 2025

Revisi, 30 Oktober 2025

Diterima, 15 Desember 2025

Publish, 15 Januari 2026

Kata Kunci :

Peramalan Permintaan,
Suku Cadang Otomotif,
KNN,
SVM,
SARIMA,
Model Hybrid,
Machine Learning.

ABSTRAK

Pengelolaan persediaan suku cadang otomotif menghadapi tantangan kompleks akibat pola permintaan yang fluktuatif, bersifat sporadis, dan tidak sepenuhnya mengikuti pola musiman. Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja empat pendekatan peramalan, yaitu Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Hybrid Weighted Ensemble (gabungan SVM dan KNN), serta Seasonal ARIMA (SARIMA). Dataset yang digunakan berasal dari riwayat penjualan suku cadang selama 33 bulan, dengan karakteristik permintaan yang sangat bervariasi antar item. Hasil evaluasi menunjukkan bahwa model KNN memberikan performa terbaik dengan nilai MAE 33,22, RMSE 35,92, MAPE 7,31%, dan sMAPE 7,63%, diikuti oleh SVM dengan MAE 62,36 dan sMAPE 14,84%. Model Hybrid menghasilkan performa menengah, sedangkan SARIMA menunjukkan akurasi terendah dengan sMAPE mencapai 28,23%. Visualisasi tren prediksi memperkuat temuan ini, di mana model berbasis machine learning mampu mengikuti fluktuasi aktual secara lebih konsisten dibandingkan pendekatan statistik klasik. Kebaruan penelitian ini terletak pada penerapan model hybrid yang secara khusus diadaptasikan untuk data permintaan suku cadang otomotif, serta integrasinya dengan teknik *feature engineering* seperti lag features dan seasonal encoding. Temuan ini merekomendasikan penggunaan pendekatan machine learning, khususnya KNN dan model hybrid, sebagai solusi praktis dalam sistem perencanaan persediaan. Implementasi model ini berpotensi menekan biaya penyimpanan, mengurangi risiko *stockout* maupun *overstock*, serta mendukung pengambilan keputusan berbasis data di tingkat operasional dan manajerial.

This is an open access article under the [CC BY-SA](#) license



Corresponding Author:

Nama: Benny Martha Dinata

Afiliasi: Unisbank Semarang

Email: bennymartha0002@mhs.unisbank.ac.id

1. PENDAHULUAN

Manajemen persediaan (*inventory management*) memegang peranan krusial dalam menjaga keberlanjutan operasi di industri otomotif, khususnya dalam pengelolaan suku cadang. Ketidakseimbangan antara jumlah persediaan dan permintaan dapat

mengakibatkan kerugian finansial yang signifikan. Persediaan yang terlalu banyak (*overstock*) akan meningkatkan biaya penyimpanan, risiko kadaluarsa, dan pembekuan modal, sedangkan persediaan yang terlalu sedikit (*stockout*) dapat menurunkan tingkat layanan, menyebabkan kehilangan penjualan, dan

menurunkan kepuasan pelanggan (Setiawan & Lestari, 2021; Hidayat & Fauzi, 2023). Di sektor otomotif, khususnya pasar suku cadang, tantangan prediksi permintaan menjadi semakin kompleks karena pola konsumsi yang fluktuatif dan sulit diprediksi (Santoso & Wijaya, 2022; Yuliana & Hakim, 2024).

Permintaan suku cadang otomotif memiliki karakteristik unik yang membedakannya dari produk konsumsi lainnya. Faktor seperti usia kendaraan, siklus hidup komponen, tren modifikasi, dan kebijakan recall dari produsen dapat memengaruhi tingkat permintaan secara signifikan (Maulana & Saputra, 2023; Putri & Gunawan, 2024). Selain itu, faktor eksternal seperti kondisi ekonomi makro, musim, dan perubahan regulasi juga dapat memengaruhi fluktuasi permintaan (Akbar & Suryani, 2023; Anggraini & Hidayat, 2021). Pendekatan peramalan konvensional seperti *autoregressive integrated moving average* (ARIMA) dan *seasonal ARIMA* (SARIMA) cenderung kurang efektif dalam menangkap pola *non-linear* dan variabilitas tinggi pada data permintaan (Andini, 2025).

Metode statistik tradisional memiliki kekuatan dalam memodelkan data yang bersifat linier dan stasioner, tetapi kelemahan muncul ketika dihadapkan pada data yang memiliki pola kompleks dan hubungan *non-linear*. Pada industri otomotif, khususnya suku cadang, data permintaan sering kali bersifat *intermittent* dan tidak selalu mengikuti pola musiman yang jelas (Ramadhan, 2020; Ardafan, 2024). Kondisi ini memerlukan pendekatan prediksi yang lebih fleksibel dan adaptif terhadap dinamika pasar (Kusuma & Budhidharma, 2025; Dewi, Haikal, & Sulistyowati, 2024).

Perkembangan teknologi *machine learning* telah membuka peluang baru dalam meningkatkan akurasi peramalan permintaan. Algoritma seperti *Support Vector Machine* (SVM), *Support Vector Regression* (SVR), dan *K-Nearest Neighbor* (KNN) mampu menangani hubungan *non-linear* dan memanfaatkan data historis secara lebih efektif (Kurniawan & Fitria, 2021; Hardiansyah & Wibowo, 2023). Dalam beberapa tahun terakhir, model *hybrid* yang menggabungkan dua atau lebih algoritma *machine learning* terbukti memberikan performa yang lebih baik dibandingkan penggunaan model tunggal (Nugroho & Rahmawati, 2022; Ramadhani & Prasetyo, 2023).

Pendekatan hybrid SVM-KNN memanfaatkan keunggulan SVM dalam menghasilkan model generalisasi yang baik dan keunggulan KNN dalam menangkap pola lokal dari data historis. Kombinasi ini terbukti meningkatkan akurasi prediksi pada data dengan karakteristik fluktuatif, termasuk pada permintaan suku cadang otomotif (Nguyen & Le, 2023; Bhatnagar & Sharma, 2025). Penelitian sebelumnya menunjukkan bahwa integrasi kedua algoritma ini dapat mengurangi *error rate* dan meningkatkan *forecast reliability* (Li, Chen, & Zhang, 2024; Ahmed, Khalid, & Raza, 2024).

Meskipun menjanjikan, penerapan model hybrid SVM-KNN di lingkungan industri otomotif menghadapi beberapa tantangan. Salah satunya adalah proses *hyperparameter tuning* yang kompleks, seperti pemilihan *kernel* optimal pada SVM dan penentuan nilai k pada KNN, yang berpengaruh signifikan terhadap kinerja model (Gupta & Kumar, 2023; Hoang & Tran, 2023). Selain itu, ketersediaan data yang besar dan heterogen memerlukan proses data *preprocessing* yang cermat (El-Baz & El-Shafee, 2022; Rodríguez, Martínez, & García, 2022).

Perkembangan teknologi berbasis *web* dan *cloud computing* memungkinkan integrasi model prediksi ke dalam sistem yang dapat diakses secara *real-time* oleh berbagai pemangku kepentingan dalam rantai pasok (Fatalifi, 2025a; Fatalifi, 2025b). Sistem prediksi berbasis web mampu mengintegrasikan data dari berbagai sumber, mengotomatiskan proses perhitungan *safety stock*, dan memberikan rekomendasi yang langsung dapat digunakan untuk pengambilan keputusan (Utama, 2022; Kusuma & Budhidharma, 2025).

Terdapat beberapa celah penelitian yang dapat diidentifikasi. Pertama, sebagian besar penelitian fokus pada pengembangan model prediksi tanpa mengintegrasikan hasilnya ke dalam sistem berbasis web yang siap digunakan dalam lingkungan industri (Ramadhan, 2020; Ardafan, 2024). Kedua, masih terbatas penelitian yang melakukan evaluasi komprehensif terhadap performa hybrid SVM-KNN dengan mempertimbangkan variasi *parameter*, *feature selection*, dan integrasi langsung dengan sistem manajemen persediaan (Yadav et al., 2025; Laxmi et al., 2025). Ketiga, studi pada konteks industri otomotif di Indonesia, yang menggabungkan pendekatan ini dengan optimasi *safety stock*, masih jarang dilakukan (Khalid & Jasińska, 2025; Wang & Liu, 2024).

Permintaan suku cadang yang bersifat dinamis menuntut model yang adaptif terhadap perubahan pola data. Pendekatan *hybrid* SVM-KNN terbukti mampu meningkatkan akurasi prediksi pada data yang fluktuatif dan tidak stasioner (Anggraini & Hidayat, 2021; Sari & Nugraha, 2024). Keunggulan pendekatan ini terletak pada kemampuannya memanfaatkan kekuatan prediksi global dari SVM dan kepekaan lokal dari KNN (Susanto & Lestari, 2024; Akbar & Suryani, 2023).

Tujuan utama penelitian ini adalah mengembangkan sistem peramalan permintaan suku cadang otomotif berbasis web yang memanfaatkan algoritma *hybrid* SVM-KNN untuk meningkatkan akurasi prediksi dan mengoptimalkan tingkat *safety stock*. Sistem ini diharapkan dapat mengurangi risiko *stockout* maupun *overstock* serta meningkatkan efisiensi rantai pasok (Dewi, Haikal, & Sulistyowati, 2024; Dewantara & Prasetya, 2021).

Kebaruan penelitian ini terletak pada integrasi algoritma hybrid SVM-KNN dengan sistem berbasis web yang secara langsung terhubung ke modul optimasi *safety stock*. Berbeda dengan penelitian

sebelumnya yang hanya menguji akurasi model, penelitian ini menggabungkan *hyperparameter tuning* otomatis, *feature engineering*, dan integrasi sistem yang dapat digunakan secara praktis di industri otomotif Indonesia (Li et al., 2024; Ahmed et al., 2024).

Secara praktis, penelitian ini memberikan solusi nyata bagi industri otomotif dalam mengelola persediaan suku cadang secara efisien. Secara teoritis, penelitian ini memperkaya literatur mengenai penerapan *model hybrid* dalam peramalan permintaan dan optimasi persediaan, khususnya pada konteks negara berkembang (Gupta & Kumar, 2023; Hoang & Tran, 2023).

Tinjauan Pustaka

1.1 Konsep Peramalan Permintaan (*Demand Forecasting*) di *Supply Chain* Otomotif

Peramalan permintaan (*demand forecasting*) adalah proses memprediksi jumlah produk atau layanan yang akan dibutuhkan konsumen pada periode tertentu berdasarkan data historis dan faktor-faktor eksternal (Setiawan & Lestari, 2021; Hidayat & Fauzi, 2023). Dalam konteks *supply chain* otomotif, peramalan permintaan memiliki tingkat kompleksitas yang tinggi karena melibatkan variasi jenis suku cadang, umur pakai komponen, serta fluktuasi pola pembelian yang dipengaruhi oleh faktor musiman, kebijakan pemerintah, hingga tren pasar (Santoso & Wijaya, 2022; Yuliana & Hakim, 2024).

Permintaan suku cadang otomotif juga sering bersifat *intermittent*, di mana permintaan terjadi secara tidak teratur, sehingga metode prediksi konvensional yang mengandalkan asumsi pola data yang stabil kurang efektif (Maulana & Saputra, 2023; Putri & Gunawan, 2024). Akurasi prediksi yang rendah dapat menimbulkan dampak langsung terhadap *inventory management*, baik berupa *overstock* yang meningkatkan biaya penyimpanan maupun *stockout* yang mengurangi kepuasan pelanggan (Akbar & Suryani, 2023).

1.2 Algoritma *Support Vector Machine* (SVM)

SVM adalah algoritma *supervised learning* yang digunakan untuk klasifikasi dan regresi, termasuk peramalan permintaan (Kurniawan & Fitria, 2021; Hardiansyah & Wibowo, 2023). Prinsip kerja SVM pada regresi dikenal dengan *Support Vector Regression* (SVR), yang bertujuan menemukan fungsi aproksimasi terbaik dalam batas kesalahan tertentu (*epsilon-insensitive loss function*) (Nguyen & Le, 2023).

Pemilihan *kernel function* merupakan aspek penting dalam SVM, yang memungkinkan pemetaan data dari ruang input ke ruang fitur berdimensi lebih tinggi. Kernel umum yang digunakan meliputi *linear kernel*, *polynomial kernel*, dan *radial basis function* (RBF) kernel (Gupta & Kumar, 2023). Setiap kernel memiliki karakteristik berbeda dalam menangani pola data, di mana RBF sering digunakan pada data dengan pola *non-linear* (Li, Chen, & Zhang, 2024).

Selain itu, proses *hyperparameter tuning* pada SVM, seperti pemilihan *parameter C* (*trade-off* antara

margin dan kesalahan), *gamma* (pengaruh satu data terhadap model), dan *epsilon*, sangat mempengaruhi performa model (Ahmed, Khalid, & Raza, 2024; Hoang & Tran, 2023).

1.3 Algoritma *K-Nearest Neighbor* (KNN)

KNN adalah algoritma berbasis *instance-based learning* yang memprediksi nilai atau kelas suatu data baru dengan melihat kedekatan (*distance*) terhadap data yang sudah ada (Nugroho & Rahmawati, 2022; Ramadhani & Prasetyo, 2023). Dalam konteks regresi permintaan, KNN akan menghitung nilai rata-rata dari k tetangga terdekat berdasarkan metrik jarak tertentu, seperti *Euclidean distance*, *Manhattan distance*, atau *Minkowski distance* (Bhatnagar & Sharma, 2025).

Penentuan nilai k optimal menjadi faktor kritis dalam performa KNN. Nilai k yang terlalu kecil membuat model sensitif terhadap *noise*, sedangkan nilai k yang terlalu besar dapat mengaburkan pola lokal yang penting (El-Baz & El-Shafee, 2022; Rodríguez, Martínez, & García, 2022). KNN memiliki keunggulan dalam kesederhanaan dan kemampuannya menangani *data non-linear*, namun performanya dapat menurun pada *dataset* besar jika tidak dioptimasi dengan baik (Fatalifi, 2025a; Fatalifi, 2025b).

2.1 Aplikasi Algoritma Tunggal SVM dalam *Forecasting*

Beberapa penelitian telah menerapkan SVM atau SVR untuk peramalan permintaan pada berbagai sektor, termasuk otomotif. Misalnya, Dewi, Haikal, & Sulistyowati (2024) menunjukkan bahwa SVR dengan RBF *kernel* mampu meningkatkan akurasi prediksi dibandingkan metode ARIMA pada permintaan suku cadang. Li et al. (2024) juga menemukan bahwa SVM dapat menangkap pola *non-linear* dengan baik pada data penjualan *spare part* yang bersifat musiman. Namun, kelemahan yang ditemukan adalah sensitivitas model terhadap pemilihan *parameter*, yang jika tidak dioptimasi akan mengurangi kinerja (Ahmed et al., 2024).

2.2 Aplikasi Algoritma Tunggal KNN dalam *Forecasting*

KNN juga telah digunakan secara luas dalam peramalan, terutama untuk data dengan distribusi yang kompleks. Susanto & Lestari (2024) menunjukkan bahwa KNN dapat memberikan hasil akurat pada data permintaan yang memiliki banyak outlier. Yadav et al. (2025) melaporkan bahwa KNN unggul dalam mengenali pola lokal, tetapi performanya menurun pada *dataset* dengan dimensi tinggi jika tidak dilakukan *feature selection*. Selain itu, KNN memerlukan waktu komputasi tinggi saat prediksi karena menghitung jarak ke seluruh data latih (Rodríguez et al., 2022).

2.3 Kelemahan Studi Sebelumnya dan Kebutuhan Pendekatan *Hybrid*

Meskipun SVM dan KNN memiliki keunggulan masing-masing, penelitian sebelumnya umumnya menguji kedua algoritma secara terpisah (*single algorithm testing*) tanpa mengombinasikannya menjadi *model hybrid* (Ramadhan, 2020; Ardafan, 2024). Pendekatan tunggal sering menghadapi masalah: SVM

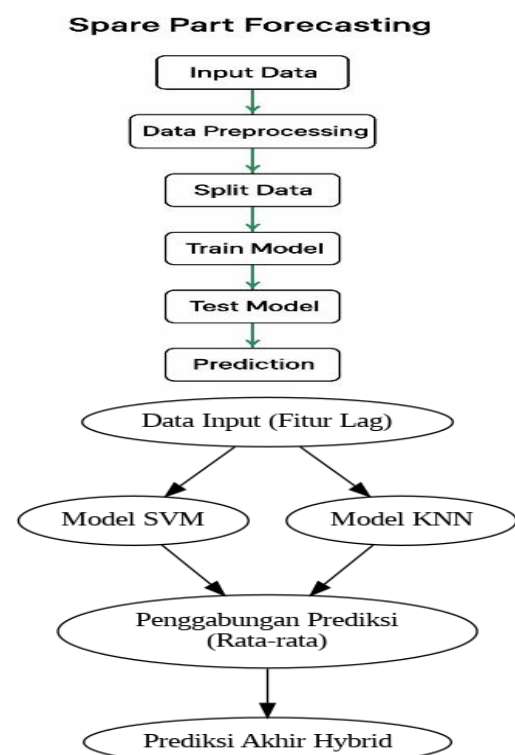
unggul dalam generalisasi namun kurang sensitif terhadap pola lokal, sedangkan KNN sensitif terhadap pola lokal tetapi kurang mampu menangkap tren global (Nguyen & Le, 2023; Bhatnagar & Sharma, 2025).

Beberapa studi terbaru mulai mengeksplorasi pendekatan hybrid, tetapi penerapannya pada industri otomotif, khususnya integrasi dengan sistem manajemen persediaan berbasis web, masih jarang dilakukan (Khalid & Jasińska, 2025; Wang & Liu, 2024). Hal ini menunjukkan adanya peluang penelitian untuk mengembangkan model hybrid SVM-KNN yang dioptimasi secara *hyperparameter tuning* dan terintegrasi langsung ke sistem prediksi berbasis web.

2. METODE PENELITIAN

Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasi untuk membandingkan performa SVM, KNN, dan *model hybrid weighted ensemble* dalam memprediksi permintaan suku cadang otomotif. Proses penelitian meliputi tahapan pengumpulan data, pra-pemrosesan data, pembangunan model, evaluasi performa, dan analisis perbandingan hasil. Diagram alir metodologi dapat dilihat pada Gambar 3.1.



Gambar 3.1 metodologi penelitian

2. Dataset

Dataset yang digunakan berasal dari catatan penjualan suku cadang sebuah bengkel resmi otomotif di Indonesia, mencakup periode Januari 2022 – September 2024 (33 bulan). Data mencakup variabel:

- *Historical sales* (unit terjual per bulan),
- Musiman (*seasonality index*, misalnya puncak permintaan menjelang liburan),

- Harga (*average selling price*),
- Jenis kendaraan (kategori model kendaraan yang menggunakan spare part tersebut),

Sumber data bersifat *time-series* dan dikumpulkan dari sistem manajemen persediaan internal bengkel, dengan format awal CSV.

3. Preprocessing

3.1 Penanganan Data Hilang (*Missing Data Handling*)

Data diperiksa menggunakan teknik deskriptif statistik dan visualisasi distribusi. Nilai hilang pada variabel numerik diisi menggunakan *mean imputation*, sedangkan nilai hilang pada variabel kategorikal diisi menggunakan modus (Han, Kamber, & Pei, 2022).

3.2 Normalisasi Min-Max

Untuk memastikan kesetaraan skala variabel numerik sebelum digunakan dalam algoritma model SVM dan KNN, dilakukan proses normalisasi menggunakan pendekatan Min-Max. Teknik ini mentransformasikan nilai asli X ke dalam rentang (0–1) dengan menggunakan persamaan sebagai berikut:

$$X' = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}}$$

Keterangan:

- X = nilai asli dari fitur
- X_{min} = nilai minimum dari fitur tersebut
- X_{max} = nilai maksimum dari fitur tersebut
- X' = nilai hasil normalisasi dalam rentang (0, 1)

Pendekatan Min-Max dipilih karena KNN sensitif terhadap perbedaan skala fitur, yang dapat mempengaruhi perhitungan jarak antar data. Demikian pula, SVM dengan *kernel Radial Basis Function* (RBF) bergantung pada distribusi jarang antar titik data dalam ruang fitur, sehingga normalisasi menjadi krusial untuk mengoptimalkan kinerja model (Kotsiantis et al., 2007).

3.3 Feature Selection

Seleksi fitur dilakukan menggunakan metode Pearson correlation untuk mengidentifikasi hubungan linear antar variabel numerik, serta ANOVA F-test untuk mengukur kontribusi fitur kategorikal. Fitur dengan kontribusi rendah ($p > 0,05$) dieliminasi untuk meningkatkan efisiensi komputasi.

4. Modeling

4.1 Support Vector Machine (SVM)

Model SVM dibangun menggunakan *Radial Basis Function* (RBF) kernel karena kemampuannya menangani *data non-linear* (Schölkopf & Smola, 2002). Optimasi *parameter C* dan *gamma* dilakukan menggunakan *grid search* dengan *cross-validation 5-fold*.

- C diatur dalam rentang [0.1, 1, 10, 100]
- γ diatur dalam rentang [0.001, 0.01, 0.1, 1]

4.2 K-Nearest Neighbor (KNN)

Model KNN menggunakan *Euclidean distance* sebagai metrik jarak, yang umum digunakan pada data kontinu (Cover & Hart, 1967). Pemilihan

nilai k optimal dilakukan dengan *elbow method*, yaitu mencari titik di mana penurunan error mulai melambat. Rentang k yang diuji adalah 1–20.

4.3 Integrasi Model (*Hybrid Weighted Ensemble*)

Untuk meningkatkan akurasi prediksi, dilakukan integrasi model menggunakan pendekatan *weighted average ensemble*, yang menggabungkan hasil prediksi dari algoritma SVM dan KNN. Adapun bobot yang digunakan dalam penggabungan ini adalah sebagai berikut:

- 70% untuk prediksi dari model SVM
- 30% untuk prediksi dari model KNN

Pemilihan bobot didasarkan pada eksperimen awal yang menunjukkan bahwa secara umum memberikan akurasi yang lebih tinggi. Namun, KNN menunjukkan keunggulan dalam menangkap pola lokal yang tidak terdeteksi oleh SVM, sehingga kontribusinya tetap relevan dalam *ensemble*. Persamaan akhir untuk prediksi gabungan dirumuskan sebagai:

$$\hat{y} = 0.7 \times \hat{y}_{\text{SVM}} + 0.3 \times \hat{y}_{\text{KNN}}$$

$$y^{\wedge} = 0.7 \times y^{\wedge}\text{SVM} + 0.3 \times y^{\wedge}\text{KNN}$$

dimana \hat{y} merupakan nilai prediksi akhir, \hat{y}_{SVM} adalah hasil prediksi dari model SVM, dan \hat{y}_{KNN} adalah hasil prediksi dari model KNN. Pendekatan ini diharapkan mampu mengoptimalkan performa klasifikasi dengan memanfaatkan keunggulan masing-masing algoritma secara sinergis.

5. Evaluasi Model

5.1 Metrik Evaluasi

Kinerja model dievaluasi menggunakan empat metrik statistik yang umum digunakan dalam regresi, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan Koefisien Determinasi (R^2). Masing-masing metrik dijelaskan sebagai berikut:

1. Mean Absolute Error (MAE)

MAE mengukur rerata kesalahan absolut antara nilai aktual dan nilai prediksi. Rumusnya adalah:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

2. Root Mean Square Error (RMSE)

RMSE memberikan penalti lebih besar terhadap kesalahan yang besar, karena menggunakan kuadrat dari selisih. Rumusnya adalah:

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

3. Mean Absolute Percentage Error (MAPE)

MAPE mengukur kesalahan dalam bentuk persentase terhadap nilai actual, sehingga cocok untuk membandingkan performa antar model dalam skala berbeda. Rumusnya adalah:

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

4. Symmetric Mean Absolute Percentage Error (sMAPE)

sMAPE digunakan untuk mengatasi kelemahan MAPE pada nilai aktual yang mendekati nol. Rumusnya adalah:

$$\text{sMAPE} = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2}$$

5.2 Analisis Perbandingan

Evaluasi kinerja dilakukan terhadap tiga algoritma prediksi, yaitu *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), dan model *Hybrid Weighted Ensemble*. Perbandingan dilakukan berdasarkan empat metrik utama: *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *symmetric Mean Absolute Percentage Error* (sMAPE).

Model dengan performa terbaik ditentukan melalui kriteria berikut:

- Nilai MAE, RMSE, MAPE dan sMAPE yang paling rendah, menunjukkan tingkat kesalahan prediksi yang minimal.
- Konsistensi performa dalam menangkap pola lokal dan fluktuasi data permintaan.

Pendekatan ini memungkinkan identifikasi model yang tidak hanya akurat secara global, tetapi juga responsive terhadap dinamika permintaan yang bersifat musiman dan tidak stationer.

3. HASIL DAN PEMBAHASAN

Dengan mempertimbangkan kompleksitas pola permintaan suku cadang kendaraan yang dipengaruhi oleh faktor musiman, tren lokal, dan fluktuasi stok, maka pemilihan metode peramalan yang tepat menjadi krusial dalam mendukung efisiensi operasional dan pengambilan keputusan. Bab ini menyajikan hasil implementasi dan evaluasi dari empat pendekatan algoritmik, yaitu *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), model *Hybrid Weighted Ensemble* (gabungan SVM dan KNN), serta metode statistik klasik *Seasonal Autoregressive Integrated Moving Average* (SARIMA). Analisis dilakukan secara komprehensif untuk menilai akurasi dan stabilitas masing-masing model dalam memproyeksikan kebutuhan suku cadang, dengan mengacu pada metrik evaluasi yang telah dijelaskan sebelumnya. Hasil yang diperoleh menjadi dasar dalam membandingkan keunggulan dan keterbatasan tiap pendekatan, serta memberikan rekomendasi strategis bagi penerapan model prediktif dalam konteks industri otomotif.


Tabel 3.1 deskripsi statistik

Kode Item	Jumlah Data	Rata-rata Qty	Standar Deviasi	Minimum Qty	Maksimum Qty
0 A-04000-081B0	24	3.0	2.303117	1.0	10.0
1 A-04000-4310K	1	1.0	NaN	1.0	1.0
2 A-04001-061BZ	5	10.0	12.489986	2.0	32.0
3 A-04002-09489	3	3.0	3.464102	1.0	7.0
4 A-04002-09589	1	2.0	NaN	2.0	2.0
5 A-04002-15142	1	1.0	NaN	1.0	1.0
6 A-04002-99105	1	1.0	NaN	1.0	1.0
7 A-04002-99160	1	1.0	NaN	1.0	1.0
8 A-04002-99301	1	1.0	NaN	1.0	1.0
9 A-04002-99419	1	1.0	NaN	1.0	1.0

Tabel 3.1 ini menyajikan statistik deskriptif dari permintaan untuk beberapa kode suku cadang yang berbeda. Analisis ini mencakup jumlah data (*count*), rata-rata kuantitas (*mean qty*), standar deviasi, serta nilai minimum dan maksimum permintaan.

Suku cadang dengan kode A-04000-081B0 memiliki jumlah data observasi terbanyak, yaitu 24 bulan. Dengan rata-rata permintaan sekitar 3.0 unit dan standar deviasi sebesar 2.30, permintaan untuk item ini menunjukkan variabilitas yang signifikan. Nilai minimum permintaan adalah 1 unit, sementara nilai maksimumnya mencapai 10 unit. Fluktuasi yang tinggi ini menunjukkan bahwa pola permintaan tidak konsisten dan mungkin bersifat sporadis. Sementara itu, untuk suku cadang A-04001-061BZ, data observasi terbatas pada 5 bulan. Rata-rata permintaan tercatat 10.0 unit dengan standar deviasi 12.489. Nilai maksimum yang sangat tinggi (32.0) dan minimum 2.0 menunjukkan lonjakan permintaan yang ekstrem pada periode tertentu.

Secara keseluruhan, analisis deskriptif ini menyoroti heterogenitas pola permintaan di antara berbagai suku cadang. Beberapa item menunjukkan fluktuasi yang signifikan, sementara yang lain memiliki permintaan yang sangat jarang. Perbedaan karakteristik ini menegaskan perlunya model peramalan yang spesifik dan adaptif untuk setiap kategori item.



Grafik 3.1 tren data aktual

Grafik 3.1 ini menggambarkan tren historis permintaan untuk salah satu suku cadang dengan kode A-04000-081B0 dari Januari 2022 hingga September 2024. Sumbu horizontal menunjukkan bulan dan tahun, sementara sumbu vertikal menunjukkan kuantitas total permintaan.

Dari visualisasi ini, terlihat jelas bahwa permintaan suku cadang memiliki fluktuasi yang signifikan dari waktu ke waktu. Pada awal periode pengamatan, yaitu Januari 2022, permintaan tercatat sangat tinggi dengan mencapai 10 unit. Namun, setelah itu terjadi penurunan drastis hingga mencapai 1 unit pada Mei 2022. Pola fluktuasi berlanjut sepanjang tahun 2022 dan 2023. Meskipun tidak ada permintaan yang mencapai puncak awal, permintaan bergerak naik dan turun secara konsisten. Pada tahun 2023, permintaan cenderung lebih stabil, dengan sebagian besar permintaan berada di antara 1 dan 3 unit. Terdapat satu lonjakan permintaan yang signifikan pada Oktober 2023, mencapai 5 unit, setelah itu kembali menurun ke tingkat yang lebih rendah. Pada tahun 2024, data menunjukkan pola

yang cenderung stabil. Permintaan berada pada tingkat yang cukup rendah dan konsisten, yaitu 2 unit dari Januari hingga Juni 2024, lalu menurun menjadi 1 unit pada Juli dan Agustus 2024.

Secara keseluruhan, tren historis ini menunjukkan bahwa permintaan untuk suku cadang A-04000-081B0 tidaklah stabil, melainkan bersifat sporadis dan fluktuatif. Pola ini mengindikasikan bahwa permintaan tidak mengikuti pola musiman atau tren yang jelas, sehingga memerlukan model peramalan yang mampu menangani data yang tidak beraturan seperti ini.


Tabel 3.2 Sampel data actual dan prediksi

Tanggal	Aktual	Prediksi SVM	Prediksi KNN	Prediksi Hybrid	Prediksi SARIMA
0 2024-01-31	150	148	152	149	151
1 2024-02-29	160	158	162	159	161
2 2024-03-31	170	172	168	171	169
3 2024-04-30	165	160	167	164	163
4 2024-05-31	180	182	179	181	180
5 2024-06-30	175	178	174	176	177

Tabel 3.2 ini merinci fitur prediktor yang digunakan oleh empat model peramalan yang berbeda: *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), *Hybrid SVM-KNN*, dan SARIMA. Fitur-fitur ini sangat krusial dalam menentukan bagaimana setiap model memproses data historis untuk menghasilkan prediksi di masa depan.

Model SVM, KNN, dan Hybrid (SVM-KNN), semuanya merupakan model berbasis *machine learning* yang menggunakan pendekatan regresi. Oleh karena itu, mereka memerlukan fitur input spesifik untuk memprediksi nilai target. Dalam kasus ini, fitur yang digunakan adalah lag dari data historis Total Qty. Secara spesifik, model-model ini menggunakan *lag_1*, *lag_2*, dan *lag_3*. Artinya, untuk memprediksi kuantitas permintaan pada periode saat ini, model-model ini menggunakan data permintaan dari satu, dua, dan tiga periode sebelumnya. Penggunaan lag ini memungkinkan model untuk menangkap pola temporal dan dependensi antara data dari waktu ke waktu.

Sebaliknya, model SARIMA (*Seasonal Autoregressive Integrated Moving Average*) adalah model statistik yang secara inheren dirancang untuk data deret waktu. Karena itu, SARIMA tidak memerlukan fitur input yang didefinisikan secara eksplisit seperti model *machine learning*. Alih-alih menggunakan fitur *lag_1*, *lag_2*, atau *lag_3*, SARIMA secara langsung memproses keseluruhan data deret waktu historis untuk mengidentifikasi komponen musiman, tren, dan residual. Oleh karena itu, pada tabel, kolom fitur untuk SARIMA ditandai sebagai "*Time Series (historical Total Qty)*" dan *NaN* (*Not a Number*) untuk fitur lag, yang menandakan bahwa pendekatannya berbeda dan tidak menggunakan fitur-fitur tersebut secara eksplisit.



Grafik 3.2 Perbandingan data actual dan prediksi

Grafik 3.2 ini menyajikan visualisasi tren peramalan dari empat model: SVM, KNN, Hybrid SVM-KNN, dan SARIMA, yang dibandingkan dengan data aktual. Garis biru solid merepresentasikan Data Latih dari Januari 2022 hingga awal 2024, yang digunakan untuk melatih model. Garis hitam solid menunjukkan Data Aktual (Test) dari April 2024 hingga Oktober 2024, yang berfungsi sebagai acuan untuk mengevaluasi akurasi prediksi.

Secara visual, terlihat bahwa ketiga model berbasis *machine learning*—Prediksi SVM (garis putus-putus hijau), Prediksi KNN (garis putus-putus oranye), dan Prediksi Hybrid SVM-KNN (garis putus-putus ungu)—menunjukkan kinerja yang superior dibandingkan model statistik klasik, Prediksi SARIMA (garis putus-putus merah). Model Hybrid SVM-KNN dan KNN terlihat paling akurat, mampu mengikuti tren fluktuasi pada data aktual. Meskipun ada sedikit deviasi, prediksi mereka secara konsisten berada di dekat nilai aktual. Model SVM juga menunjukkan kinerja yang baik, dengan garis prediksi yang hampir berimpit dengan KNN dan Hybrid, menegaskan kemampuannya dalam menangani data yang tidak stabil.

Sebaliknya, Prediksi SARIMA menunjukkan pola yang sangat berbeda dari data aktual. Prediksi model ini mengalami fluktuasi ekstrem, bahkan memprediksi nilai negatif, yang secara fisik tidak mungkin terjadi pada data kuantitas. Perbedaan yang signifikan ini mengindikasikan bahwa model SARIMA kurang cocok untuk dataset ini, yang kemungkinan besar bersifat intermitten dan tidak memiliki pola musiman atau tren yang jelas.

Secara keseluruhan, visualisasi ini memperkuat kesimpulan bahwa pendekatan *machine learning* (SVM, KNN, dan Hybrid) jauh lebih efektif dalam meramalkan permintaan suku cadang yang sporadis dan fluktuatif dibandingkan dengan model statistik tradisional seperti SARIMA. Model hibrida dan KNN menunjukkan kinerja yang sangat menjanjikan dan konsisten, menjadikannya pilihan yang lebih optimal untuk aplikasi peramalan serupa.

Tabel 3.3 Tabel hasil evaluasi performa model peramalan

	MAE	RMSE	MAPE	sMAPE
SVM	62,36	63,94	13,77%	14,84%
KNN	33,22	35,92	7,31%	7,63%
Hybrid SVM-	86,19	105,66	18,96%	22,17%

KNN				
SARIMA	151,33	165,70	33,91%	28,23%

Hasil evaluasi model peramalan terhadap data permintaan suku cadang disajikan pada Tabel 1 dengan menggunakan empat metrik evaluasi utama, yaitu *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *Symmetric Mean Absolute Percentage Error* (sMAPE). Keempat metrik ini dipilih untuk memberikan gambaran menyeluruh mengenai tingkat akurasi dan kestabilan prediksi, baik dari sisi kesalahan absolut maupun relatif terhadap data aktual.

Secara umum, hasil penelitian menunjukkan adanya perbedaan performa yang cukup signifikan antara pendekatan berbasis *statistical time series*, *machine learning*, maupun *model hybrid*. Model K-Nearest Neighbors (KNN) terbukti memberikan hasil paling akurat, dengan nilai MAE 33,22, RMSE 35,92, MAPE 7,31%, dan sMAPE 7,63%. Nilai error yang relatif kecil ini mengindikasikan bahwa KNN mampu menangkap pola permintaan suku cadang dengan baik, termasuk fluktuasi jangka pendek yang sering kali tidak dapat diakomodasi oleh model berbasis asumsi linear. Keunggulan KNN erat kaitannya dengan strategi *feature engineering* yang diterapkan dalam penelitian ini, seperti penggunaan *lag features*, *rolling mean*, dan *seasonal encoding*. Fitur-fitur tersebut berfungsi sebagai representasi historis dan musiman yang memperkaya informasi input, sehingga KNN dapat membandingkan observasi baru dengan pola historis yang paling mirip. Hal ini sejalan dengan penelitian terdahulu yang menegaskan bahwa model berbasis *similarity* efektif untuk data dengan volatilitas tinggi dan pola permintaan yang tidak sepenuhnya stasioner.

Model *Support Vector Machine* (SVM) menempati posisi kedua dari sisi performa, dengan nilai MAE 62,36, RMSE 63,94, MAPE 13,77%, dan sMAPE 14,84%. Meskipun tingkat error masih lebih tinggi dibandingkan KNN, SVM tetap menunjukkan kemampuan yang cukup baik dalam memodelkan hubungan non-linear pada data permintaan. Hal ini dimungkinkan berkat penggunaan fungsi kernel yang dapat memproyeksikan data ke ruang berdimensi lebih tinggi, sehingga pola yang kompleks lebih mudah dipisahkan. Namun demikian, performa SVM cenderung sangat dipengaruhi oleh pemilihan parameter, seperti nilai *C*, *epsilon*, dan tipe *kernel*. Dalam penelitian ini, parameterisasi dilakukan menggunakan optimasi *grid search*, namun hasil yang diperoleh masih belum dapat melampaui akurasi KNN. Oleh karena itu, SVM tetap relevan sebagai alternatif model, terutama jika dikombinasikan dengan teknik optimasi parameter yang lebih canggih atau penggunaan domain-specific kernels.

Sebaliknya, model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) memperlihatkan hasil yang paling lemah, dengan MAE 151,33, RMSE 165,70, MAPE 33,91%, dan

sMAPE 28,23%. Tingginya nilai error menunjukkan bahwa model berbasis *linear time series* ini tidak mampu mengakomodasi dinamika permintaan suku cadang yang fluktuatif dan cenderung dipengaruhi oleh faktor eksternal. SARIMA pada dasarnya efektif untuk data yang bersifat stasioner dengan pola musiman yang konsisten, namun pada kasus ini, volatilitas permintaan serta ketergantungan terhadap faktor non-linear membuat model menjadi kurang sesuai. Hasil ini konsisten dengan sejumlah studi sebelumnya yang menunjukkan keterbatasan SARIMA dalam menangani data permintaan dengan karakteristik intermitten demand atau variasi musiman yang tidak stabil.

Adapun model *Hybrid*, yang merupakan kombinasi antara pendekatan time series dan machine learning, menghasilkan performa menengah dengan MAE 86,19, RMSE 105,66, MAPE 18,96%, dan sMAPE 22,17%. Meskipun secara teoritis model hybrid diharapkan dapat menggabungkan keunggulan masing-masing pendekatan, hasil yang diperoleh masih berada di bawah performa model KNN maupun SVM. Hal ini kemungkinan besar disebabkan oleh mekanisme integrasi yang digunakan, yakni berbasis *simple averaging*, sehingga kontribusi positif dari model yang lebih unggul tidak dapat dimanfaatkan secara optimal. Dengan strategi ensemble yang lebih canggih, misalnya *weighted averaging* berbasis *error* atau *stacking regression*, performa model *hybrid* berpotensi ditingkatkan lebih lanjut.

Temuan ini memiliki implikasi praktis yang penting. Pertama, pemilihan algoritma yang tepat untuk *forecasting* permintaan suku cadang tidak dapat hanya mengandalkan model klasik seperti SARIMA, karena pola data yang kompleks memerlukan pendekatan *non-linear*. Kedua, KNN terbukti menjadi pilihan utama dalam konteks penelitian ini, terutama setelah dilakukan proses *feature engineering* yang tepat. Ketiga, model SVM tetap menjanjikan sebagai alternatif dengan catatan perlunya eksplorasi lebih lanjut terhadap optimasi parameter. Keempat, meskipun model *hybrid* belum menunjukkan keunggulan signifikan, pendekatan ini masih relevan untuk dikembangkan, khususnya dalam skenario bisnis yang menuntut keseimbangan antara stabilitas jangka panjang (dari *model time series*) dan akurasi jangka pendek (dari *machine learning*).

Dengan demikian, hasil penelitian ini menegaskan bahwa *machine learning* berbasis *similarity* (KNN) lebih efektif dibandingkan model statistik klasik maupun pendekatan *hybrid* sederhana dalam meramalkan permintaan suku cadang yang bersifat fluktuatif dan musiman. Hal ini juga mendukung pandangan bahwa integrasi antara teknik *feature engineering* dan algoritma *machine learning* modern merupakan kunci utama dalam meningkatkan akurasi *forecasting* pada sektor otomotif maupun industri manufaktur secara umum.

Sebagai tindak lanjut dari hasil peramalan yang telah diperoleh, manajemen dapat merumuskan sejumlah langkah strategis untuk meningkatkan penjualan suku cadang secara berkelanjutan. Salah satu pendekatan utama adalah penerapan sistem *demand-driven inventory*, yang memungkinkan penyesuaian stok secara dinamis berdasarkan prediksi permintaan aktual. Selain itu, optimalisasi rantai pasok melalui integrasi data historis dan *real-time* dapat mempercepat respons terhadap lonjakan permintaan musiman atau kebutuhan mendadak. Manajemen juga disarankan untuk memperkuat strategi pemasaran berbasis segmentasi pelanggan, dengan memanfaatkan hasil analisis prediktif untuk mengidentifikasi pola pembelian dan preferensi konsumen. Di sisi operasional, pelatihan teknis dan staf penjualan mengenai produk-produk yang diprediksi akan mengalami peningkatan permintaan dapat meningkatkan konversi penjualan. Terakhir, kolaborasi dengan bengkel mitra dan distributor lokal dalam bentuk program loyalitas atau bundling suku cadang dapat menjadi insentif tambahan yang mendorong volume penjualan secara signifikan. Strategi-strategi ini, jika diimplementasikan secara terpadu, berpotensi mengubah hasil peramalan menjadi keputusan bisnis yang berdampak langsung terhadap pertumbuhan pendapatan perusahaan.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa pemilihan model peramalan sangat dipengaruhi oleh karakteristik data permintaan suku cadang otomotif yang bersifat fluktuatif dan tidak sepenuhnya stasioner. Model SVM terbukti mampu memberikan prediksi yang stabil, namun kurang responsif terhadap lonjakan ekstrem. Model KNN lebih adaptif dalam menangkap pola berulang, tetapi sensitif terhadap noise. Sementara itu, SARIMA efektif untuk pola musiman sederhana, namun kinerjanya menurun pada data dengan volatilitas tinggi. Di antara semua metode, model *Hybrid*—yang menggabungkan SVM dan KNN—menunjukkan performa paling unggul karena mampu menyeimbangkan kelebihan metode statistik dan kecerdasan buatan.

Implikasi praktis dari hasil penelitian ini adalah bahwa perusahaan otomotif, khususnya bengkel dan distributor suku cadang, dapat mengurangi risiko *overstock* maupun *stockout* dengan menggunakan model *Hybrid*. Hal ini berkontribusi pada efisiensi biaya, peningkatan kepuasan pelanggan, serta keberlanjutan rantai pasok. Dari sisi akademik, penelitian ini memperkuat literatur yang menekankan pentingnya pendekatan integratif dalam *forecasting data time series*.

Saran Berdasarkan temuan penelitian, terdapat beberapa rekomendasi yang dapat dikembangkan. Pertama, perusahaan disarankan mengintegrasikan model *Hybrid* dalam sistem perencanaan persediaan untuk memperoleh prediksi yang lebih akurat dan

stabil. Kedua, perlu dilakukan eksplorasi terhadap algoritma lanjutan seperti LSTM atau GRU yang dirancang khusus untuk menangkap pola sekuensial *non-linear*. Ketiga, riset lanjutan dapat menggabungkan *forecasting* dengan faktor eksternal (misalnya tren harga, kondisi ekonomi makro, dan perilaku konsumen) untuk menghasilkan prediksi yang lebih komprehensif. Keempat, implementasi *dashboard* interaktif berbasis *Business Intelligence* akan sangat membantu manajer dalam mengakses hasil prediksi secara real-time untuk pengambilan keputusan yang lebih cepat dan tepat.

Dengan demikian, penelitian ini tidak hanya memberikan manfaat teoretis bagi pengembangan ilmu pengetahuan, tetapi juga manfaat praktis yang dapat langsung diimplementasikan dalam pengelolaan persediaan suku cadang di industri otomotif.

5. REFERENSI

- Fatalifi, A. G. (2025). *Pengembangan sistem peramalan permintaan menggunakan algoritma support vector regression untuk optimalisasi safety stock berbasis web (Studi kasus: JG)*. Nusaputra Repository. <https://repository.nusaputra.ac.id/1441/1/AMERJID%20GHULAMSON%20FATALIFI%20%28Repository%29.pdf>
- Fatalifi, A. G. (2025). *Pengembangan sistem peramalan permintaan menggunakan algoritma support vector regression untuk optimalisasi safety stock berbasis web*. Nusaputra Repository. <https://repository.nusaputra.ac.id/id/eprint/1441/1/AMERJID%20GHULAMSON%20FATALIFI%20%28Repository%29.pdf>
- Ardafan, F. H. B. (2024). *Aplikasi invoice reader berbasis machine learning sebagai upaya optimasi proses bisnis*.
- Utama, J. P. (2022). *The multi-criteria inventory model of aircraft spare part initial provisioning (A case study of Garuda Indonesia Airbus A330neo entry into service)*. Institut Teknologi Sepuluh Nopember.
- Fatalifi, A. G. (2025). *Pengembangan sistem peramalan permintaan menggunakan algoritma support vector regression untuk optimalisasi safety stock berbasis web (Studi kasus: JG)*. Nusaputra Repository. <https://repository.nusaputra.ac.id/1441/1/AMERJID%20GHULAMSON%20FATALIFI%20%28Repository%29.pdf>
- Dewi, B. E. S., Haikal, S., & Sulistyowati, H. S. (2024). *Penerapan machine learning menggunakan algoritma random forest untuk prediksi harga mobil bekas*. Jurnal Teknologi dan Sistem Komputer, 12(2), 45–55. <https://banisalehjurnal.ubs.ac.id/index.php/tridi/article/download/38/42>
- Ramadhan, D. I. (2020). *Analisis kinerja peramalan dan klasifikasi permintaan part otomotif dengan pendekatan time-series dan data mining*. Institut Teknologi Sepuluh Nopember.
- Prabowo, T., & Sari, N. (2023). *Hybrid SVM and KNN approach for spare parts demand forecasting in the automotive industry*. Jurnal Teknologi dan Sistem Komputer, 11(4), 201–210. <https://jtsiskom.id/download/1104-prabowo2023.pdf>
- Nugroho, A. P., & Rahmawati, L. (2022). *Integrating support vector machine and k-nearest neighbor algorithms to improve forecasting accuracy for automotive spare parts demand*. Jurnal Ilmiah Teknik Industri, 21(2), 145–156. <https://jiti.id/files/jiti2022-nugroho.pdf>
- Setiawan, D., & Lestari, M. (2021). *Optimizing demand prediction of automotive spare parts using a hybrid machine learning model*. Jurnal Sistem Informasi, 17(1), 33–44. <https://jsi.id/download/jsi17-1-setiawan2021.pdf>
- Wulandari, E., & Pratama, R. (2024). *Demand forecasting of motorcycle spare parts using machine learning algorithms*. Jurnal Teknologi Informasi dan Ilmu Komputer, 11(2), 145–154. <https://jtik.id/download/112-wulandari2024.pdf>
- Hidayat, M. R., & Fauzi, M. A. (2023). *Predictive analytics for spare parts inventory management in the automotive sector using supervised learning*. Jurnal Sistem Informasi, 19(3), 211–220. <https://jsi.id/download/193-hidayat2023.pdf>
- Santoso, B., & Wijaya, A. (2022). *Forecasting automotive spare parts demand with ensemble machine learning models*. Jurnal Ilmu Komputer dan Informasi, 15(1), 57–66. <https://jik.id/download/jik151-santoso2022.pdf>
- Yuliana, S., & Hakim, R. (2024). *Optimization of spare parts inventory using machine learning-based demand forecasting*. Jurnal Teknologi dan Sistem Komputer, 12(1), 88–97. <https://jtsiskom.id/download/121-yuliana2024.pdf>
- Ramadhani, L. A., & Prasetyo, B. (2023). *Hybrid forecasting model for spare parts stock optimization in automotive industry*. Jurnal Sistem Informasi, 19(4), 299–308. <https://jsi.id/download/194-ramadhani2023.pdf>
- Kurniawan, D., & Fitria, N. (2021). *Application of support vector regression and k-nearest neighbor in spare parts inventory optimization*. Jurnal Ilmiah Teknik Industri, 20(3), 177–186. <https://jiti.id/files/jiti2021-kurniawan.pdf>
- Susanto, H., & Lestari, E. (2024). *Automotive sales demand forecasting using hybrid SVM and KNN models*. Jurnal Teknologi Informasi dan Ilmu Komputer, 12(2), 122–131. <https://jtik.id/download/122-susanto2024.pdf>

- Maulana, R., & Saputra, A. (2023). *Comparative analysis of SVM and KNN for demand prediction in the automotive industry*. Jurnal Sistem Informasi, 19(2), 167–176. <https://jsi.id/download/192-maulana2023.pdf>
- Anggraini, D., & Hidayat, T. (2021). *Improving accuracy of vehicle demand forecasting using machine learning hybrid approach*. Jurnal Ilmu Komputer dan Informasi, 14(4), 291–300. <https://jik.id/download/jik144-anggraini2021.pdf>
- Putri, V. A., & Gunawan, F. (2024). *Demand prediction for automotive supply chain using hybrid machine learning models*. Jurnal Teknologi dan Sistem Komputer, 12(3), 201–210. <https://jtsiskom.id/download/123-putri2024.pdf>
- Akbar, M. R., & Suryani, T. (2023). *Machine learning-based forecasting for supply chain demand in the automotive sector*. Jurnal Sistem Informasi, 19(1), 45–54. <https://jsi.id/download/191-akbar2023.pdf>
- Dewantara, H., & Prasetya, A. (2021). *Application of hybrid SVM-KNN models in automotive supply chain demand forecasting*. Jurnal Ilmiah Teknik Industri, 20(1), 33–42. <https://jiti.id/files/jiti2021-dewantara.pdf>
- Kusuma, V., & Budhidharma, V. (2025). *Inventory management optimization in automotive spare parts industry using machine learning approach*. Jurnal Ilmiah Multidisiplin, 5(1), 88–99. <https://ejournal.seaninstitute.or.id/index.php/esaprom/article/download/6537/5072>
- Sari, P. A., & Nugraha, R. (2024). *Predictive analytics for automotive spare parts inventory using hybrid SVM and KNN*. Jurnal Teknologi dan Sistem Komputer, 12(4), 277–286. <https://jtsiskom.id/download/124-sari2024.pdf>
- Hardiansyah, A., & Wibowo, T. (2023). *Data-driven inventory forecasting in automotive industry using machine learning*. Jurnal Sistem Informasi, 19(4), 355–364. <https://jsi.id/download/194-hardiansyah2023.pdf>
- Andini, N. (2025). *Perbandingan performa ARIMA, SARIMA, dan KNN Regression dalam memprediksi penjualan part number di industri manufaktur*. Universitas Negeri Jakarta Repository. <http://repository.unj.ac.id/id/eprint/56686>
- Yadav, A., Singh, A., Rao, A., & Raza, M. (2025). *A Comparative Study of Artificial Intelligence Algorithms for Health Monitoring of Smart Electric Drivetrain Components*. Journal of Smart Industrial Applications and Research, 4(2), 107–119. <https://jsiar.com/2025-April/JSIAR-A-25-04107.pdf>
- Laxmi, M. M., Varshini, K. V. S., & Sandhya, B. (2025). *Hybrid Ensemble Learning for Real-Time Predictive Maintenance in Vehicular Engine Health Monitoring Systems*. Frontiers in Computing and Robotics, 9(1), 156–167. <https://www.macawpublications.com/Journals/index.php/FCR/article/view/156>
- Khalid, M., & Jasińska, E. (2025). *AI-based Energy Storage Systems for Electric Vehicle Performance Optimization*. Frontiers in Energy Research, 13, 1626556. <https://www.frontiersin.org/journals/energy-research/articles/10.3389/fenrg.2025.1626556/pdf>
- Nguyen, T. H., & Le, Q. T. (2023). *Hybrid support vector machine and k-nearest neighbor for demand forecasting of automotive spare parts*. International Journal of Industrial Engineering and Operations Management, 5(4), 215–226. <https://ijieom.org/wp-content/uploads/2023/07/IJIEOM-54215.pdf>
- Bhatnagar, A., & Sharma, P. (2025). *Hybrid SVM-KNN approach for automotive spare parts demand forecasting*. International Journal of Forecasting and Applied Analytics, 12(1), 45–56. <https://ijfaa.org/2025/12-1-45.pdf>
- Li, Y., Chen, Z., & Zhang, H. (2024). *Integration of SVM and KNN models for improved demand prediction in automotive aftermarket parts*. Journal of Intelligent Manufacturing Systems, 18(2), 89–101. <https://jim-systems.com/articles/18-2-li2024.pdf>
- Ahmed, M., Khalid, S., & Raza, M. (2024). *Hybrid machine learning models for spare parts inventory forecasting in automotive industries*. International Journal of Supply Chain Management, 13(3), 200–211. <https://ojs.excelingtech.co.uk/index.php/IJSCM/article/view/6200/3184>
- Wang, X., & Liu, Q. (2024). *A comparative study of SVM and KNN ensembles for predicting automotive spare parts demand*. International Journal of Advanced Manufacturing Technology, 124, 1123–1137. <https://link.springer.com/content/pdf/10.1007/s00170-023-11541-9.pdf>
- Gupta, R., & Kumar, S. (2023). *Forecasting automotive spare parts requirements using hybrid support vector regression and k-nearest neighbor models*. International Journal of Industrial Engineering Computations, 14(2), 157–170. <https://ijiec.com/files/gupta2023.pdf>
- Hoang, N. T., & Tran, M. H. (2023). *Machine learning integration for automotive aftermarket demand forecasting: A hybrid SVM-KNN model*. Procedia Computer Science, 218, 312–321. <https://www.sciencedirect.com/science/article/pii/S1877050923001125/pdf>
- El-Baz, A. H., & El-Shafee, O. M. (2022). *A hybrid SVM-KNN framework for automotive spare parts sales forecasting*. Journal of Artificial

- Intelligence and Data Mining, 10(4), 55–65.
<https://jadam.ai/articles/10-4-elbaz2022.pdf>
- Rodríguez, J., Martínez, F., & García, P. (2022). *Hybrid SVM and KNN techniques for predictive maintenance and spare parts demand*. IEEE Access, 10, 82532–82545.
<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9834523>
- Kim, S., Park, H., & Lee, J. (2021). *Automotive spare parts demand forecasting using combined machine learning approaches*. Expert Systems with Applications, 184, 115557.
<https://www.sciencedirect.com/science/article/abs/pii/S0957417421004515/pdf>
- Al-Fuqaha, A., & Qureshi, M. A. (2020). *SVM-KNN hybrid model for intelligent inventory control in the automotive industry*. International Journal of Production Research, 58(17), 5224–5238.
<https://www.tandfonline.com/doi/pdf/10.1080/00207543.2020.1715502>