



Multivariate Support Vector Regression for Intermittent Spare Parts Demand Forecasting in the Railway Industry

Multivariat Support Vector Regression untuk Peramalan Permintaan Suku Cadang Intermittent pada Industri Perkeretaapian

Syayid Al Afghoni^{1*}, Iwan Vanany²

¹Sekolah Interdisiplin Manajemen Teknologi, Institut Teknologi Sepuluh Nopember, Indonesia

²Departemen Teknik Sistem dan Industri, Institut Teknologi Sepuluh Nopember, Indonesia

E-Mail: ¹6032241001@student.its.ac.id, ²vanany@its.ac.id

Received Jan 29th 2026; Revised Mar 04th 2026; Accepted Apr 08th 2026; Available Online Apr 26th 2026

Corresponding Author: Syayid Al Afghoni

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Spare parts inventory management in the railway industry faces complex challenges due to intermittent demand patterns. Inaccuracies in forecasting maintenance component requirements often lead to stockout risks that disrupt operations or overstock situations that burden holding costs. This study aims to enhance spare parts forecasting accuracy by developing a Support Vector Regression (SVR) model that integrates exogenous variables, specifically maintenance schedule frequency and fleet age classification. Utilizing historical train maintenance spare parts consumption data from PT KAI's Maintenance Workshop for the period 2020–2024, the SVR model's performance was evaluated and benchmarked against Croston's method and Random Forest. The test results demonstrate that the RBF-kernel-based SVR model effectively handles data volatility, achieving the lowest error rates (MAE 8,424 dan MASE 0,449). The model proved superior to Croston's method, which tended to under-forecast, and Random Forest, which was less responsive to extreme values. These findings indicate that integrating maintenance cycle information and fleet age profiles significantly improves the model's generalization capability on fluctuating data. Managerially, the implementation of this model enables more proactive inventory planning, supports safety stock optimization, and ensures spare parts availability for train fleet reliability.

Keywords: Demand Forecasting, Intermittent, Spare Parts, Support Vector Regression (SVR).

Abstrak

Manajemen persediaan suku cadang dalam industri perkeretaapian menghadapi tantangan kompleks akibat pola permintaan yang bersifat *intermittent*. Ketidakakuratan dalam meramalkan kebutuhan komponen perawatan sering kali berujung pada risiko *stockout* yang menghambat operasional atau *overstock* yang membebani biaya penyimpanan. Penelitian ini bertujuan untuk meningkatkan akurasi peramalan suku cadang dengan mengembangkan model *Support Vector Regression* (SVR) yang mengintegrasikan variabel eksogen berupa frekuensi jadwal perawatan dan klasifikasi umur armada. Menggunakan data historis pemakaian suku cadang perawatan kereta di workshop perawatan PT KAI periode 2020–2024, kinerja model SVR dievaluasi dan dibandingkan dengan metode *Croston* serta *Random Forest*. Hasil pengujian menunjukkan bahwa model SVR berbasis kernel RBF mampu menangani volatilitas data secara efektif dengan menghasilkan tingkat kesalahan terendah (MAE 8,424 dan MASE 0,449). Model ini terbukti superior dibandingkan metode *Croston* yang cenderung *under-forecasting* dan *Random Forest* yang kurang responsif terhadap nilai ekstrem. Temuan ini mengindikasikan bahwa integrasi informasi siklus perawatan dan profil usia armada secara signifikan memperbaiki kemampuan generalisasi model pada data yang fluktuatif. Secara manajerial, penerapan model ini memungkinkan perencanaan inventori yang lebih proaktif, mendukung optimalisasi *safety stock*, dan menjamin ketersediaan suku cadang untuk keandalan armada kereta api.

Kata Kunci: *Intermittent*, Peramalan Permintaan, Suku Cadang, *Support Vector Regression* (SVR).

1. PENDAHULUAN

Dalam industri transportasi kereta api modern, manajemen ketersediaan suku cadang merupakan elemen krusial dalam memitigasi risiko *downtime* operasional. Tidak adanya ketersediaan suku cadang tidak

hanya menghambat jadwal perawatan rutin, tetapi juga dapat memicu efek domino yang merugikan, mulai dari gangguan layanan operasional dan penurunan tingkat kepuasan pelanggan hingga beban finansial yang signifikan bagi perusahaan. Sebagai langkah preventif, peramalan permintaan (*demand forecasting*) menjadi instrumen wajib untuk menjamin kontinuitas ketersediaan suku cadang di gudang. Namun, efektivitas pengelolaan inventori ini sering kali dihadapkan pada karakteristik permintaan suku cadang yang bersifat tidak menentu dan memiliki fluktuasi yang tinggi [1]. Kondisi ini menunjukkan bahwa strategi manajemen suku cadang memerlukan pendekatan spesifik yang berbeda dengan pengelolaan produk konsumen pada umumnya [2].

Ketidakpastian permintaan suku cadang dalam industri perawatan sering kali memicu pola permintaan suku cadang yang bersifat non-linear dan fluktuatif. Tantangan fundamental dalam proses peramalan ini terletak pada karakteristik data yang bersifat *intermittent* dan *lumpy*. Permintaan *intermittent* dicirikan oleh fluktuasi nilai yang acak dengan kemunculan interval nol (*zero demand*) yang dominan dalam periode tertentu [3]. Sementara itu, pola *lumpy* menunjukkan tingkat kompleksitas yang lebih tinggi, di mana selain memiliki banyak periode bernilai nol, variabilitas antar volume permintaannya juga sangat ekstrem [4]. Mengingat karakteristiknya yang spesifik, kedua pola permintaan tersebut memerlukan pendekatan analitis khusus guna menghasilkan akurasi peramalan yang optimal.

PT Kereta Api Indonesia (PT KAI), sebagai penyedia layanan transportasi perkeretaapian terbesar di Indonesia, menghadapi tantangan signifikan dalam manajemen perawatan armada kereta, khususnya terkait fluktuasi permintaan suku cadang. Kondisi operasional di workshop menunjukkan adanya kendala dalam menyusun perencanaan kebutuhan material yang reliabel akibat karakteristik data yang tidak konsisten. Kehadiran pola permintaan *intermittent* dan *lumpy* menciptakan kompleksitas bagi manajemen dalam memproyeksikan kebutuhan di masa depan. Ketidakpastian ini meningkatkan risiko perusahaan terhadap fenomena *stockout* yang menghambat durasi perawatan, maupun *overstock* yang memicu inefisiensi biaya penyimpanan. Oleh karena itu, penelitian mengenai peramalan pola permintaan yang tidak menentu ini menjadi sangat krusial guna memperkuat efektivitas operasional dan menjaga keberlanjutan layanan PT KAI dalam jangka panjang.

Metode peramalan konvensional, seperti *Moving Average* dan *Exponential Smoothing*, sering kali menunjukkan performa yang tidak optimal saat dihadapkan pada volatilitas permintaan yang tinggi [5]. Teknik-teknik tradisional tersebut umumnya berbasis pada asumsi linearitas dan kontinuitas data, sehingga cenderung menghasilkan bias yang signifikan ketika diaplikasikan pada pola *intermittent* atau *lumpy* yang didominasi oleh nilai nol [6]. Sebagai alternatif yang lebih adaptif, pendekatan *Machine Learning* (ML) melalui *Support Vector Regression* (SVR) menawarkan kapabilitas yang lebih unggul dalam menangani karakteristik data tersebut [7]. Melalui implementasi *kernel trick*, SVR memiliki kemampuan untuk memetakan data ke dalam ruang dimensi yang lebih tinggi, sehingga mampu menangkap kompleksitas pola permintaan yang bersifat non-linear dan variatif secara lebih presisi dibandingkan metode statistik konvensional [8].

Efektivitas SVR dalam memproyeksikan permintaan suku cadang yang bersifat *intermittent* telah divalidasi oleh berbagai studi empiris lintas sektor, namun berbagai literatur sepakat menyoroti perlunya pengembangan lebih lanjut. Dalam konteks industri militer, Boukhtouta & Jentsch [9] menunjukkan bahwa SVR mampu menghasilkan prediksi yang akurat, tapi masih berbasis fungsi waktu dan merekomendasikan untuk mengintegrasikan variabel independen eksternal seperti waktu operasi. Sejalan dengan hal tersebut, penggunaan ϵ -SVR oleh Li et al. [10] Pada alat pertahanan, dikemukakan bahwa peningkatan performa model memerlukan pengayaan faktor-faktor yang memengaruhi permintaan serta optimasi parameter yang lebih adaptif. Di sektor alat berat, pengembangan model *Adaptive Univariate SVM* (AUSVM) oleh Jiang et al. [11] membuktikan bahwa varian SVR mampu menangani data *intermittent*, namun mereka menyarankan perlunya uji coba pada berbagai skenario data yang lebih fluktuatif. Selain itu, Wang & Zhang [8] yang menggunakan SVR pada industri peralatan mekanik, menyarankan perlunya mengintegrasikan faktor-faktor eksternal yang memengaruhi permintaan untuk mendukung manajemen perawatan preventif. Temuan-temuan tersebut secara konsisten menunjukkan bahwa pengembangan model peramalan perlu diarahkan pada integrasi variabel operasional yang relevan untuk meningkatkan kualitas prediksi.

Berdasarkan tinjauan literatur tersebut, keterbatasan pendekatan peramalan SVR masih dominan bersifat univariat dan belum secara optimal mengintegrasikan variabel operasional yang berperan sebagai pemicu utama permintaan. Meskipun SVR telah diterapkan secara global, pemodelan yang secara eksplisit mengintegrasikan faktor penyebab permintaan seperti siklus perawatan dan degradasi usia aset armada masih sangat terbatas, khususnya dalam konteks industri perkeretaapian di Indonesia. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model SVR berbasis kernel *Radial Basis Function* (RBF) dengan pendekatan multivariat yang mengintegrasikan variabel frekuensi aktivitas perawatan preventif dan klasifikasi umur armada sebagai prediktor. Pendekatan ini diharapkan mampu meningkatkan akurasi peramalan sekaligus memberikan representasi yang lebih realistis terhadap hubungan antara aktivitas operasional dan kebutuhan suku cadang *intermittent*.

2. METODE PENELITIAN

2.1. Data Penelitian


Data penelitian ini bersumber dari data riil salah satu workshop perawatan kereta PT KAI periode 2020–2024. Dataset terdiri dari variabel target (*dependent variable*) berupa volume konsumsi suku cadang, serta variabel independen yang mencakup frekuensi perawatan dan profil usia armada. Data perawatan difokuskan pada siklus perawatan P24 dan P48. Sementara itu, untuk menangkap pengaruh usia aset terhadap kebutuhan suku cadang, data umur kereta diklasifikasikan menjadi tiga klaster: (1) usia muda (<15 tahun), (2) usia menengah (15–30 tahun), dan (3) usia tua (>30 tahun). Gambaran struktur *dataset* yang digunakan dalam penelitian disajikan pada Tabel 1.

Tabel 1. Dataset penelitian 2020-2024 (60 data)

Bulan ke-	Demand Qty	Jml P24	Jml P48	Jml Kereta <15 Th	Jml Kereta 15-30 Th	Jml Kereta >30 Th
1	8	0	0	33	3	19
2	20	13	37	66	6	8
3	32	13	47	51	6	23
.....						
28	14	47	33	51	6	23
29	0	7	14	13	4	4
30	12	7	14	13	1	7
.....						
58	14	22	20	21	6	4
59	24	11	34	18	5	11
60	0	0	0	0	0	0

2.2. Alur Penelitian

Penelitian ini dirancang secara sistematis sebagaimana ditunjukkan pada Gambar 1. Proses penelitian diawali dengan pengumpulan dan pra-pemrosesan data (*pre-processing*) untuk memastikan kualitas *input* model. Dalam studi ini, peramalan permintaan suku cadang dimodelkan dengan mengintegrasikan variabel eksogen berupa frekuensi perawatan dan klasifikasi usia armada. Dataset yang digunakan memiliki time frame bulanan selama periode 2020–2024, sehingga menghasilkan total 60 titik observasi.




Gambar 1. Diagram Metode Penelitian

Untuk keperluan evaluasi dan validasi model, skema partisi data (*data splitting*) diterapkan dengan memisahkan dataset menjadi dua bagian: periode 2020–2023 (48 bulan) dialokasikan sebagai data *training set* untuk pembentukan model, sedangkan data tahun 2024 (12 bulan) digunakan sebagai data *testing set*. Guna mengukur efektivitas metode yang diusulkan, performa akurasi model SVR akan dikomparasikan dengan metode *Croston* yang umum digunakan untuk peramalan *intermittent* serta algoritma *Random Forest* sebagai representasi pendekatan *ensemble machine learning*.

2.3. Support Vector Regression (SVR)

Support Vector Regression (SVR) merupakan pengembangan dari algoritma *Support Vector Machine* (SVM) yang diperkenalkan oleh Vapnik (1995) untuk menangani kasus data kontinu [12]. Jika SVM konvensional bertujuan mencari *hyperplane* terbaik untuk memisahkan kelas data (klasifikasi), SVR bertujuan menemukan fungsi regresi $f(x)$ yang memiliki deviasi maksimum sebesar ϵ dari target aktual y_i untuk seluruh data latih, sekaligus menjaga fungsi tersebut sedatar mungkin (*flatness*) [13].

Konsep SVR terletak pada *epsilon-insensitive tube*. Seperti diilustrasikan pada Gambar 2, hanya titik data yang berada di luar zona toleransi ϵ (disebut sebagai *Support Vectors*) yang akan diperhitungkan dalam pembentukan fungsi regresi (penalti error). Sifat ini menjadikan SVR memiliki resistensi yang tinggi terhadap *overfitting* dan efisien dalam komputasi karena tidak semua data latih memengaruhi model akhir.



Gambar 2. Konsep Model SVR [14]

Secara matematis, fungsi regresi pada SVR dapat dirumuskan sebagai berikut:

$$f(x) = w\phi(x) + b \quad (1)$$

Dimana $f(x)$ adalah nilai prediksi, w adalah vektor bobot (*weight vector*), b adalah bias, dan $\phi(x)$ merupakan fungsi pemetaan data input (x) ke ruang fitur yang lebih tinggi.

Untuk mendapatkan garis regresi terbaik, SVR meminimalkan fungsi objektif berikut dengan memperhitungkan kompleksitas model dan error prediksi, yang ditunjukkan pada Persamaan 2.

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*), C > 0 \quad (2)$$

dengan batasan:

$$\begin{aligned} y_i - w\phi(x_i) - b &\leq \epsilon + \xi_i \\ w\phi(x_i) + b - y_i &\leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \quad (3)$$

dengan:

- ϵ : Parameter yang mendefinisikan zona toleransi (*epsilon-insensitive tube*),
- ξ_i dan ξ_i^* : *Slack variables* untuk data di luar batas ϵ ,
- C : Mengontrol kompromi antara kompleksitas model dan toleransi terhadap error.

Mengingat pola permintaan suku cadang sering kali bersifat non-linear, SVR menerapkan *kernel trick* untuk memetakan data input ke ruang dimensi tinggi tanpa harus menghitung transformasi $\phi(x)$ secara eksplisit [15]. Fungsi kernel yang paling umum digunakan dalam peramalan *time-series* adalah *Radial Basis Function* (RBF) karena kemampuannya menangkap hubungan non-linear lokal secara efektif [8], [16]. Fungsi kernel RBF ditunjukkan pada Persamaan 4.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (4)$$

Dimana γ adalah parameter kernel yang mengatur jangkauan pengaruh dari satu data latih. Nilai γ yang kecil berarti jangkauan pengaruh yang jauh, sedangkan nilai besar berarti jangkauan sempit. Dengan menerapkan metode *Lagrange Multipliers* untuk menyelesaikan masalah optimasi di atas, fungsi keputusan akhir SVR diperoleh dalam bentuk dual yang ditunjukkan pada Persamaan 5

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x_t) + b \quad (5)$$

Dimana α_i dan α_i^* adalah pengali Lagrange yang nilainya tidak nol hanya untuk data yang menjadi *Support*

Vectors. Kombinasi optimal dari *hyperparameter* C , ϵ , dan γ sangat menentukan performa model, yang dalam penelitian ini akan ditentukan melalui metode pencarian *RandomSearch* dengan validasi silang (*Cross-Validation*).

Pemilihan metode Support Vector Regression (SVR) dalam penelitian ini didasarkan pada kemampuannya secara fundamental dalam menangani hubungan non-linear serta kondisi data dengan jumlah yang terbatas [10], yang merupakan karakteristik utama dari pola permintaan *intermittent*. Penggunaan Kernel RBF juga memberikan fleksibilitas tambahan untuk memodelkan pola non-linear lokal pada data time-series yang bersifat fluktuatif dan tidak stasioner. Kernel ini memungkinkan pemetaan data ke ruang fitur berdimensi tinggi tanpa perlu melakukan transformasi secara eksplisit, sehingga SVR mampu menangkap hubungan kausalitas yang kompleks antara variabel eksogen (aktivitas perawatan dan umur armada) dengan fluktuasi permintaan suku cadang.

2.4. Metode Croston

Metode *Croston* (1972) [17] dan variannya secara luas diakui sebagai pendekatan standar (*baseline*) dalam literatur peramalan inventori untuk menangani pola permintaan *intermittent* [17], [18]. Keunggulan fundamental metode ini terletak pada mekanisme dekomposisi peramalan menjadi dua komponen terpisah, yaitu estimasi besaran permintaan (*demand size*) dan estimasi interval waktu antar-kedatangan permintaan (*inter-arrival time*).

Berbeda dengan *Single Exponential Smoothing* (SES) konvensional yang memperbarui estimasi pada setiap periode waktu, prinsip kerja Metode *Croston* adalah hanya melakukan pembaruan parameter (*update*) ketika terjadi transaksi permintaan aktual ($y_t > 0$). Jika tidak terjadi permintaan ($y_t = 0$), maka nilai estimasi periode sebelumnya akan dipertahankan.

Secara matematis, jika y_t adalah permintaan aktual pada periode t , dan $(p_t - \hat{p}_{t-1})$ adalah jumlah periode yang berlalu sejak permintaan terakhir, maka pembaruan estimasi ukuran permintaan (z_t) dan interval permintaan (p_t) dilakukan menggunakan persamaan eksponensial smoothing sebagai berikut:

$$\text{jika } y_t > 0 : \begin{cases} \hat{z}_t = \hat{z}_{t-1} + \alpha(z_t - \hat{z}_{t-1}) \\ \hat{p}_t = \hat{p}_{t-1} + \alpha(p_t - \hat{p}_{t-1}) \end{cases} \quad \text{jika } y_t = 0 : \begin{cases} \hat{z}_t = \hat{z}_{t-1} \\ \hat{p}_t = \hat{p}_{t-1} \end{cases}$$

Adapun nilai peramalan akhir ($\hat{y}_t$) didefinisikan sebagai rasio antara estimasi ukuran permintaan terhadap estimasi interval, ditunjukkan pada Persamaan 6.

$$\hat{y}_t = \frac{\hat{z}_t}{\hat{p}_t} \quad (6)$$

dengan:

$\hat{y}_t$	: Nilai peramalan periode t
$\hat{z}_t$	: Estimasi ukuran permintaan
$\hat{p}_t$	: Estimasi interval antar permintaan
α	: Smoothing parameter ($0 < \alpha < 1$)

Dalam penelitian ini metode *Croston* akan digunakan sebagai model pembandingan terhadap model yang diusulkan.

2.5. Random Forest

Random Forest (RF), yang diperkenalkan oleh Breiman (2001), merupakan metode *ensemble learning* yang mengkonstruksi sekumpulan pohon keputusan (*decision trees*) pada saat pelatihan [19]. Algoritma ini beroperasi dengan prinsip *Bootstrap Aggregating* (*Bagging*), di mana setiap pohon dilatih menggunakan *subset* data yang diambil secara acak dengan pengembalian (*random sampling with replacement*) [20]. RF mencari fitur terbaik dari *subset* fitur yang dipilih secara acak. Mekanisme ini bertujuan untuk meningkatkan diversitas (keragaman) antar-pohon serta mereduksi risiko *overfitting* yang sering menjadi kelemahan pada pohon keputusan tunggal.

Untuk kasus regresi, prediksi akhir model diperoleh dengan merata-ratakan hasil prediksi dari seluruh pohon individu yang terbentuk. Secara matematis, fungsi regresi RF didefinisikan sebagai berikut:

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T f_t(x) \quad (7)$$

dengan:

$\hat{y}$	: Nilai prediksi akhir
T	: Jumlah pohon dalam hutan,

f_t : Model prediksi regresi pohon ke- t ,
 x : Vektor fitur input.

Dalam penelitian ini, *Random Forest* digunakan sebagai model pembanding *machine learning* non-kernel untuk menguji apakah model SVR yang diusulkan memiliki performa yang lebih robust dalam meramalkan suku cadang dengan pola *intermittent*.

2.6. Evaluasi Model

Evaluasi model merupakan fase fundamental dalam prosedur peramalan untuk memvalidasi tingkat reliabilitas hasil prediksi terhadap data aktual. Mengingat karakteristik data suku cadang yang bersifat *intermittent* dan mengandung banyak nilai nol (*sparse data*), pemilihan metrik evaluasi yang tepat menjadi sangat krusial. Penelitian ini mengadopsi dua indikator kinerja utama, yaitu *Mean Absolute Error* (MAE) dan *Mean Absolute Scaled Error* (MASE).

2.6.1. Mean Absolute Error (MAE)

MAE digunakan untuk mengukur rata-rata magnitudo kesalahan absolut antara nilai prediksi dan nilai aktual tanpa memperhatikan arah kesalahan (positif atau negatif). Keunggulan utama MAE adalah interpretasinya yang intuitif karena diekspresikan dalam satuan unit yang sama dengan data asli, sehingga sangat relevan untuk konteks operasional manajemen inventori [21].

MAE didefinisikan pada Persamaan 8.

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (8)$$

dengan:

y_t : Nilai aktual data
 $\hat{y}_t$: Nilai prediksi data
 n : Jumlah data

Nilai MAE yang semakin mendekati nol mengindikasikan akurasi model yang semakin tinggi.

2.6.2. Mean Absolute Scaled Error (MASE)

MASE, yang diperkenalkan oleh Hyndman (2006), diadopsi untuk mengatasi kelemahan metrik berbasis persentase (seperti MAPE) yang menjadi tidak terdefinisi saat berhadapan dengan data bernilai nol. MASE mengukur performa model dengan membandingkan *Mean Absolute Error* dari model yang diusulkan terhadap *Mean Absolute Error* dari metode naif [22]. Sifatnya yang *scale-invariant* menjadikan MASE sebagai standar baku dalam evaluasi peramalan data *intermittent*. MASE didefinisikan pada Persamaan 9.

$$ASE = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{\left(\frac{1}{n-1} \sum_{t=2}^n |y_t - y_{t-1}|\right)} \quad (9)$$

Dimana penyebut (denominator) merupakan rata-rata kesalahan absolut dari metode peramalan naif (dimana prediksi periode depan diasumsikan sama dengan periode sekarang, $\hat{y}_t = y_{t-1}$).

Kriteria interpretasi nilai MASE adalah sebagai berikut:

1. $MASE < 1$: Model yang diusulkan memiliki performa yang lebih baik dibandingkan metode naif.
2. $MASE > 1$: Model yang diusulkan memiliki performa lebih buruk daripada metode naif.

Dalam penelitian ini, kombinasi kedua metrik tersebut digunakan secara komplementer. MAE berfungsi untuk memberikan gambaran kesalahan dalam satuan unit fisik (jumlah suku cadang) yang mudah dipahami oleh manajemen PT KAI, sedangkan MASE berfungsi sebagai validasi statistik yang objektif untuk membuktikan ketangguhan model dalam menangani pola *zero-demand*.

3. HASIL DAN PEMBAHASAN

3.1 Analisa Pola Permintaan Suku Cadang

Analisis karakteristik data diawali dengan observasi visual terhadap perilaku permintaan suku cadang di *workshop* perawatan PT KAI. Sebagaimana ditunjukkan pada Gambar 3, plot data *time series* menunjukkan adanya volatilitas yang tinggi. Terlihat jelas bahwa profil permintaan tidak stasioner, di mana

terdapat banyak periode dengan nilai permintaan nol (*zero demand*), namun diselingi oleh lonjakan permintaan (*spikes*) yang ekstrem pada bulan-bulan tertentu (seperti pada periode ke-13 dan ke-33).



Gambar 3. Fluktuasi Pola Permintaan Suku Cadang *Intermittent*

Untuk memvalidasi observasi visual tersebut secara statistik, dilakukan perhitungan nilai *Average Demand Interval* (ADI) dan *Squared Coefficient of Variation* (CV^2). Berdasarkan hasil perhitungan data, diperoleh nilai metrik sebagai berikut:


1. ADI = 1.33
2. $CV^2 = 0.40$

Dengan mengacu pada klasifikasi pola permintaan menurut Syntetos et al. (2005) [18], suatu permintaan dikategorikan sebagai *Intermittent* apabila memenuhi syarat $ADI \geq 1.32$ dan $CV^2 < 0.49$. Dengan nilai ADI sebesar 1.33 dan CV^2 0.40, maka dapat disimpulkan bahwa suku cadang ini memiliki pola permintaan *Intermittent*. Hal ini mengonfirmasi bahwa penggunaan metode peramalan konvensional (seperti rata-rata) akan bias, dan pendekatan khusus seperti *Croston* atau SVR sangat diperlukan.

3.2 Evaluasi Kinerja Model Peramalan SVR

Tahap awal pembentukan model dimulai dengan penentuan konfigurasi hyperparameter yang optimal untuk kernel *Radial Basis Function* (RBF). Melalui teknik pencarian *Randomized Search CV*, diperoleh kombinasi parameter terbaik yang meminimalkan fungsi kerugian (*loss function*), yakni: C 502, epsilon 0,570, dan gamma 0,0018.


Kinerja model pada fase *training* ditunjukkan pada Gambar 4. Secara kualitatif, kurva prediksi SVR (garis putus-putus biru) menunjukkan tingkat kesesuaian (*goodness of fit*) yang tinggi terhadap data aktual (garis hitam). Model terbukti mampu menangkap dinamika fluktuasi permintaan dengan presisi yang baik, yang diindikasikan oleh sinkronisasi fase antara lonjakan prediksi dan aktual. Hal ini mengonfirmasi bahwa variabel eksogen yang diusulkan (frekuensi perawatan P24/P48 dan klasifikasi umur) memiliki daya jelas yang kuat terhadap variabilitas permintaan.



Gambar 4. Model SVR Training

Selanjutnya, validasi kemampuan generalisasi model dilakukan pada data uji (*testing set*) tahun 2024, sebagaimana disajikan pada Gambar 5. Secara kuantitatif, model SVR menunjukkan performa yang superior dengan capaian nilai MAE sebesar 8,424 dan MASE sebesar 0,449. Nilai MASE yang kurang dari 1 memberikan bukti statistik yang kuat bahwa model yang diusulkan jauh lebih akurat dibandingkan metode peramalan naif. Analisis visual pada Gambar 5 memperlihatkan responsivitas model yang adaptif. Pada periode dengan permintaan tinggi (seperti bulan ke-50), model mampu melakukan eskalasi prediksi

mendekati nilai puncak aktual. Sebaliknya, keunggulan utama model ini terlihat pada kemampuannya menangani periode tanpa permintaan (*zero demand*), seperti yang terjadi pada bulan ke-52 dan ke-60. Pada titik-titik tersebut, kurva prediksi melandai mendekati nol secara presisi.



Gambar 5. Model SVR Testing

Kemampuan mendeteksi *zero demand* ini sangat krusial bagi manajemen inventori PT KAI, yakni untuk mencegah keputusan pengadaan yang tidak perlu (*over-forecasting*) yang berujung pada penumpukan *dead stock*. Meskipun performa keseluruhan sangat baik, teridentifikasi adanya deviasi *under-forecasting* pada bulan ke-54, di mana lonjakan aktual lebih tinggi dari prediksi model. Deviasi ini kemungkinan besar disebabkan oleh faktor permintaan insidental (seperti kerusakan mendadak atau faktor eksternal lain) yang tidak terakomodasi dalam variabel jadwal perawatan rutin. Namun, secara agregat, model SVR terbukti *robust* dalam menangani karakteristik data *intermittent*.

Tabel 2 menyajikan komparasi kuantitatif kinerja model antara fase *training* dan *testing*. Teridentifikasi di mana kinerja model pada fase *testing* justru lebih baik dibandingkan *training*, yang ditandai dengan penurunan nilai MAE dari 9,453 menjadi 8,424 dan MASE dari 0,504 menjadi 0,449. Secara teoritis, kondisi di mana *Testing Error* lebih rendah daripada *Training Error* mengindikasikan bahwa model memiliki kapabilitas generalisasi yang sangat kuat (*robust generalization*). Fenomena ini dapat dijelaskan melalui tinjauan karakteristik data. Periode *training* (2020–2023) mencakup rentang waktu yang memiliki variabilitas ekstrem, termasuk dampak pandemi COVID-19 yang menyebabkan fluktuasi permintaan suku cadang menjadi sangat tidak menentu (*high noise*). Sebaliknya, periode *testing* (2024) merepresentasikan kondisi operasional yang relatif lebih stabil.

Tabel 2. Perbandingan Kinerja Model SVR pada data *Training* dan *Testing*

Metrik Evaluasi	Training (2020-2023)	Testing (2024)
MAE	9,453	8,424
MASE	0,504	0,449


Kemampuan model SVR untuk menghasilkan *error* yang lebih kecil pada data baru (2024) membuktikan bahwa model tidak mengalami *overfitting* terhadap *noise* yang ada pada data training, melainkan berhasil mengekstraksi pola tren fundamental yang valid untuk memprediksi kebutuhan masa depan.

3.3 Perbandingan Kinerja Model (SVR vs *Croston* vs RF)

Evaluasi komparatif bertujuan untuk mengetahui performa model yang diusulkan (SVR) terhadap metode standar industri (*Croston*) dan metode *machine learning* berbasis *ensemble* (*Random Forest*). Ringkasan kinerja kuantitatif ketiga model disajikan pada Tabel 3. Berdasarkan metrik MAE dan MASE, model SVR secara konsisten menunjukkan performa yang lebih baik dari pada kedua model perbandingan. SVR mencatatkan nilai MAE terendah sebesar 8,424 dan MASE terendah sebesar 0,449 mengungguli *Random Forest* dan *Croston*.

Tabel 3. Komparasi Kinerja Model Peramalan

Method	MAE	MASE
SVR	8,424	0,449
RF	9,750	0,520
<i>Croston</i>	15,072	0,803



Gambar 6. Komparasi Kinerja Model Peramalan

Gambar 6 menyajikan perbandingan visual antara nilai aktual dan hasil prediksi masing-masing model. Garis prediksi metode *Croston* menunjukkan pola yang cenderung datar (flat) dan relatif stasioner sepanjang periode pengujian. Hal ini mencerminkan keterbatasan metode statistik univariat dalam menangani permintaan yang dipengaruhi oleh faktor eksternal, seperti jadwal perawatan (P24 dan P48) serta klasifikasi umur armada. Akibatnya, pada periode dengan lonjakan permintaan, metode *Croston* cenderung menghasilkan prediksi yang lebih rendah dari kebutuhan aktual (under-forecasting), yang berpotensi meningkatkan risiko *stockout* dalam operasional perawatan.

Model Random Forest menunjukkan pola prediksi yang lebih dinamis dibandingkan *Croston*. Namun demikian, grafik memperlihatkan bahwa model ini cenderung kesulitan dalam menangkap nilai puncak (peak demand), seperti yang terlihat pada periode dengan lonjakan permintaan. Keterbatasan ini berkaitan dengan karakteristik algoritma berbasis pohon keputusan yang mengandalkan mekanisme averaging, sehingga menghasilkan prediksi yang lebih konservatif dan kurang mampu melakukan ekstrapolasi terhadap nilai ekstrem.

Model pembanding berbasis *machine learning* seperti Random Forest (orange) menunjukkan respons yang lebih dinamis dibandingkan *Croston*. Namun, grafik memperlihatkan bahwa RF cenderung kesulitan mencapai nilai puncak (peak values) dari data aktual (Seperti bulan ke-50). Keterbatasan ini bisa disebabkan oleh karakteristik algoritma pohon keputusan yang tidak mampu melakukan ekstrapolasi nilai di luar rentang data latih (training range). Mengingat data suku cadang ini bersifat *intermittent* dengan jumlah sampel kejadian ekstrem yang sedikit, RF cenderung bermain aman dengan merata-ratakan hasil prediksi dari banyak pohon (averaging), sehingga gagal memprediksi lonjakan permintaan yang tajam secara akurat.

Model yang diusulkan, yaitu SVR dengan kernel RBF, menunjukkan performa paling baik dengan kemampuan mengikuti pola fluktuasi permintaan secara lebih adaptif. Garis prediksi SVR memperlihatkan kesesuaian fase yang kuat dengan data aktual, mampu meningkat pada periode dengan aktivitas perawatan tinggi, serta menurun mendekati nol pada periode tanpa permintaan. Hal ini menunjukkan bahwa integrasi variabel eksogen, seperti frekuensi perawatan dan klasifikasi umur armada, berkontribusi dalam meningkatkan kemampuan model dalam merepresentasikan pola permintaan *intermittent*.

Secara keseluruhan, hasil ini menunjukkan bahwa pendekatan SVR multivariat lebih robust dalam menangani karakteristik data *intermittent* dibandingkan metode konvensional maupun model berbasis ensemble. Selain itu, integrasi variabel operasional dalam model peramalan terbukti membantu mengurangi bias prediksi yang umumnya muncul pada data dengan dominasi nilai nol (zero demand), sehingga menghasilkan estimasi yang lebih akurat dan representatif terhadap kondisi operasional.

3.4 Implikasi Manajerial

Implikasi manajerial dari penelitian ini adalah memberikan justifikasi *data-driven* bagi PT KAI. Implikasi manajerial dapat dipetakan ke dalam dua aspek utama:

1. Penurunan biaya inventory: Dengan ketidakpastian permintaan yang dapat dipetakan lebih baik, perusahaan dapat mengurangi *buffer stock* yang berlebihan tanpa mengorbankan target *service level*. Reduksi volume stok ini berkorelasi linier dengan penurunan biaya simpan (*holding cost*) dan pelepasan modal kerja yang sebelumnya tertahan dalam bentuk inventori pasif (*idle inventory*).
2. Mitigasi risiko: Model mampu mendeteksi peningkatan probabilitas kebutuhan suku cadang pada armada tua, sehingga memitigasi risiko *stockout* yang fatal bagi operasional perawatan. Sebaliknya, pada armada baru dengan tingkat kerusakan rendah, model mencegah terjadinya pengadaan prematur yang berpotensi menjadi *dead stock*.

3. Secara spesifik, implikasi manajerial dari penelitian ini adalah memberikan justifikasi *data-driven* bagi PT KAI untuk mereduksi *safety stock* pada armada baru, sekaligus memitigasi risiko *stockout* pada armada tua, yang secara langsung akan menurunkan biaya *holding inventory*. Sebagai arah penelitian selanjutnya, sangat direkomendasikan untuk mengintegrasikan model peramalan ini dengan formulasi *Economic Order Quantity* (EOQ) probabilistik guna menghitung penghematan biaya secara nominal, serta mengeksplorasi penggunaan algoritma *Deep Learning* seperti LSTM untuk membandingkan performanya dengan model SVR ini pada horizon waktu jangka panjang.

4. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan, penelitian ini membuktikan bahwa integrasi jadwal perawatan dan klasifikasi umur armada sebagai variabel prediktor secara signifikan mampu meningkatkan akurasi peramalan suku cadang *intermittent*. Model mampu mendeteksi pola lonjakan kebutuhan (*spikes*). Evaluasi komparatif menunjukkan bahwa model *Support Vector Regression* (SVR) dengan kernel RBF menghasilkan kinerja yang paling superior dibandingkan dengan metode *baseline Croston* dan *Random Forest*. SVR mencatatkan tingkat kesalahan terendah dengan nilai MAE sebesar 8,424 dan MASE sebesar 0,449. Hal ini mengonfirmasi bahwa arsitektur SVR lebih *robust* dalam menangani karakteristik keterbatasan data (*data scarcity*) dan volatilitas tinggi pada suku cadang *intermittent*. Penerapan model ini berpotensi meningkatkan efisiensi rantai pasok melalui optimalisasi *safety stock* yang adaptif, sehingga risiko *stockout* dapat dimitigasi tanpa membebani biaya penyimpanan secara berlebihan.

Penelitian ini dapat dikembangkan lebih lanjut dengan mempertimbangkan penambahan variabel lain yang relevan, seperti data kilometer tempuh kereta atau data historis kerusakan komponen spesifik (*failure rate*), untuk memperkaya dimensi pembelajaran model atau dengan menggabungkan model SVR dengan model *machine learning* lainnya agar peramalan menjadi lebih akurat. Selain itu, selanjutnya penelitian ini juga dapat diintegrasikan dengan kebijakan inventori seperti model perhitungan *Economic Order Quantity* (EOQ) probabilitas, penentuan *Reorder Point* (ROP) dinamis, serta penentuan *safety stock* untuk menghitung potensi penghematan total biaya persediaan (*total inventory cost*).

REFERENSI

- [1] T. B. Affonso, S. V. Conceição, L. R. Muniz, J. F. de Freitas Almeida, and J. C. de Lima, "A new hybrid forecasting method for spare part inventory management using heuristics and bootstrapping," *Decision Analytics Journal*, vol. 10, Mar. 2024, doi: 10.1016/j.dajour.2024.100415.
- [2] S. Zhang, K. Huang, and Y. Yuan, "Spare parts inventory management: A literature review," *Sustainability (Switzerland)*, vol. 13, no. 5, pp. 1–23, Mar. 2021, doi: 10.3390/su13052460.
- [3] Z. Hua and B. Zhang, "A hybrid support vector machines and logistic regression approach for forecasting intermittent demand of spare parts," *Appl. Math. Comput.*, vol. 181, no. 2, pp. 1035–1048, Oct. 2006, doi: 10.1016/j.amc.2006.01.064.
- [4] M. R. Amin-Naseri and B. R. Tabar, "Neural network approach to lumpy demand forecasting for spare parts in process industries," in *2008 International Conference on Computer and Communication Engineering*, 2008, pp. 1378–1382. doi: 10.1109/ICCCE.2008.4580831.
- [5] O. M. Nabil, N. H. Afia, and T. Ismail, "Intermittent Demand Forecasting for Spare Parts Using Artificial Neural Networks and Deep Learning: Literature Review," *JES. Journal of Engineering Sciences*, vol. 0, no. 0, pp. 0–0, Jul. 2025, doi: 10.21608/jesaun.2025.386170.1518.
- [6] S. Fatemeh Faghidian, M. Khashei, and M. Khalilzadeh, "Improving intermittent demand forecasting based on data structure," *Journal of Engineering Research (Kuwait)*, vol. 9, no. 1, pp. 188–199, Feb. 2021, doi: 10.36909/JER.V9I1.8667.
- [7] Y. Bao, W. Wang, and J. Zhang, "Forecasting intermittent demand by SVMs regression," in *2004 IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No.04CH37583)*, 2004, pp. 461–466 vol.1. doi: 10.1109/ICSMC.2004.1398341.
- [8] S. Wang and J. Zhang, "Research on Spare Parts Demand Forecasting for Mechanical and Electrical Equipment Based on Preventive Maintenance," in *2024 8th International Conference on Electrical, Mechanical and Computer Engineering, ICEMCE 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 1492–1496. doi: 10.1109/ICEMCE64157.2024.10862827.
- [9] A. Boukhtouta and P. Jentsch, "Support Vector Machine for Demand Forecasting of Canadian Armed Forces Spare Parts," in *2018 6th International Symposium on Computational and Business Intelligence (ISCBI)*, 2018, pp. 59–64. doi: 10.1109/ISCBI.2018.00021.
- [10] X. Li, X. Zhao, and W. Pu, "Battle damage-oriented spare parts forecasting method based on wartime influencing factors analysis and ϵ -support vector regression," *Int. J. Prod. Res.*, vol. 58, no. 4, pp. 1178–1198, Feb. 2020, doi: 10.1080/00207543.2019.1614691.
- [11] P. Jiang, Y. Huang, and X. Liu, "Intermittent demand forecasting for spare parts in the heavy-duty vehicle industry: a support vector machine model," *Int. J. Prod. Res.*, vol. 59, no. 24, pp. 7423–7440, 2021, doi: 10.1080/00207543.2020.1842936.

-
- [12] V. N. Vapnik, *The Nature of Statistical Learning Theory*, 2nd ed. New York, NY: Springer New York, 1995. doi: 10.1007/978-1-4757-3264-1.
 - [13] F. Zhang and L. J. O'Donnell, "Support vector regression," in *Machine Learning: Methods and Applications to Brain Disorders*, Elsevier, 2019, pp. 123–140. doi: 10.1016/B978-0-12-815739-8.00007-9.
 - [14] A. Aktepe, E. Yanık, and S. Ersöz, "Demand forecasting application with regression and artificial intelligence methods in a construction machinery company," *J. Intell. Manuf.*, vol. 32, no. 6, pp. 1587–1604, Aug. 2021, doi: 10.1007/s10845-021-01737-8.
 - [15] T. L. Palgunadi, R. Fitriana, A. N. Habyba, and Y. C. Liang, "Optimizing Demand Forecasting Method with Support Vector Regression for Improved Inventory Planning," *Jurnal Optimasi Sistem Industri*, vol. 23, no. 2, pp. 149–166, 2024, doi: 10.25077/josi.v23.n2.p149-166.2024.
 - [16] H. Liang, Y. Zhang, T. Liu, C. Guo, and Z. Qi, "Research on forecasting method of mechanical equipment spare parts demand based on LS-SVM," *International Journal of Frontiers in Engineering Technology*, vol. 5, no. 3, 2023, doi: 10.25236/ijfet.2023.050301.
 - [17] J. D. Croston, "Forecasting and Stock Control for Intermittent Demands," *Operational Research Quarterly (1970-1977)*, vol. 23, no. 3, pp. 289–303, 1972.
 - [18] A. A. Syntetos, J. E. Boylan, and J. D. Croston, "On the categorization of demand patterns," *Journal of the Operational Research Society*, vol. 56, no. 5, pp. 495–503, 2005, doi: 10.1057/palgrave.jors.2601841.
 - [19] L. Breiman, "Random Forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
 - [20] G. Dudek, "Short-term load forecasting using random forests," *Advances in Intelligent Systems and Computing*, vol. 323, pp. 821–828, 2015, doi: 10.1007/978-3-319-11310-4_71.
 - [21] I. Shafi *et al.*, "Spare Parts Forecasting and Lumpiness Classification Using Neural Network Model and Its Impact on Aviation Safety," *Applied Sciences (Switzerland)*, vol. 13, no. 9, May 2023, doi: 10.3390/app13095475.
 - [22] R. Hyndman, "Another Look at Forecast Accuracy Metrics for Intermittent Demand," *Foresight: The International Journal of Applied Forecasting*, vol. 4, pp. 43–46, Nov. 2006.