

Analisis Optimalisasi Safety Stock dengan Metode Regresi Linear Support Vector dan Neural Network

Agus Dwi Churniawan¹⁾, Titik Lusiani²⁾, Tutut Wurijanto³⁾, Teguh Sutanto⁴⁾, Didiet Anindita Arnandy⁵⁾

¹⁾ S1 Sistem Informasi, FTI, Universitas Dinamika, agusdwi@dinamika.ac.id

²⁾ ⁵⁾ D3 Sistem Informasi, FTI, Universitas Dinamika, lusiani@dinamika.ac.id

³⁾ S1 Sistem Informasi, FTI, Universitas Dinamika, tutut@dinamika.ac.id

⁴⁾ S1 Sistem Informasi, FTI, Universitas Dinamika, teguh@dinamika.ac.id

Abstrak

Manajemen inventaris yang efektif memerlukan penentuan Stok Pengaman (*Safety Stock*) yang optimal di tengah tingginya fluktuasi permintaan. Metode tradisional yang menggunakan Standar Deviasi permintaan historis mentah cenderung bersifat reaktif dan menghasilkan dilema kelebihan stok (*overstock*) atau kekurangan stok (*stockout*). Penelitian ini bertujuan untuk menganalisis dan membandingkan efektivitas tiga metode *Machine Learning* (ML) yaitu Regresi Linier (RL), Support Vector Regression (SVR), dan Neural Network (NN) dalam mengoptimalkan perhitungan *Safety Stock*. Model ML digunakan untuk menjelaskan variabilitas permintaan, sehingga secara drastis mengurangi Standar Deviasi Kesalahan Prediksi. Tahapan penelitian meliputi pengumpulan data fitur (tren, suhu, promosi), pemodelan ML, evaluasi menggunakan *Root Mean Squared Error* (RMSE), dan perhitungan *Safety Stock* (SS). Hasil penelitian menunjukkan peningkatan efisiensi yang signifikan dibandingkan metode dasar. Regresi Linier mencapai efisiensi 68% (SS 17.27 unit), SVR mencapai 70% efisiensi (SS 16.12 unit) karena kemampuannya menangani *outlier*, dan Neural Network mencapai efisiensi tertinggi 71% (SS 15.63 unit) karena unggul pada data non-linier dan kompleks. Pemilihan model yang tepat harus disesuaikan dengan pola fitur data untuk menghemat biaya inventaris secara maksimal.

Kata Kunci: *Safety Stock*, Regresi Linier, Support Vector Regression, Neural Network, Optimalisasi Inventaris.

PENDAHULUAN

Manajemen inventaris yang efektif merupakan pilar utama keunggulan operasional dan profitabilitas perusahaan. Di tengah lingkungan pasar yang ditandai oleh fluktuasi permintaan yang tinggi dan ketidakpastian rantai pasok (*supply chain*), tantangan terbesar adalah menentukan tingkat Stok Pengaman (*Safety Stock*) yang optimal. Metode tradisional dalam menghitung *Safety Stock*, yang bergantung pada Standar Deviasi permintaan historis mentah, sering kali bersifat reaktif dan gagal memperhitungkan hubungan kompleks antara permintaan dengan berbagai faktor eksternal (musiman, promosi, harga, dll.). Akibatnya, perusahaan cenderung menghadapi dilema biaya, kelebihan stok (*overstock*) yang membebani biaya

penyimpanan dan risiko kedaluwarsa, atau kekurangan stok (*stockout*) yang menyebabkan hilangnya penjualan dan pelanggan.

Regresi Linier (RL) dianggap sebagai model dasar sebagai *baseline* komparatif yang penting yang dilakukan oleh Smith et al. (2020) menegaskan bahwa RL tetap efektif dalam menjelaskan komponen tren dan musiman yang bersifat linier dalam permintaan. Namun, kegagalan RL dalam menangkap *spikes* permintaan tak terduga mendorong tren menuju pendekatan hibrida. Studi Jones & Lee (2021), misalnya, menggabungkan RL dengan dekomposisi *time-series* untuk sedikit meningkatkan akurasi, tetapi tetap terbatas oleh asumsi linieritas dan sensitivitasnya terhadap *outlier*

Support Vector Regression (SVR) pemodelan non-linier melalui *Kernel Trick* dan karakteristiknya yang kuat (*robust*) terhadap data ekstrem menurut Wang & Kim (2022) telah membandingkan RL dan SVR untuk prediksi permintaan *e-commerce*, menemukan bahwa SVR secara signifikan mengurangi RMSE lebih kecil untuk *Safety Stock* terutama di segmen produk dengan permintaan yang sangat *volatile*. Demikian pula, Al-Mansoori et al. (2023) menunjukkan bahwa SVR, dengan penyesuaian *hyperparameter* yang cermat, berhasil memberikan estimasi *Safety Stock* yang lebih stabil dan efisien dibandingkan metode tradisional *Safety Stock* berbasis variansi, karena SVR lebih efektif dalam menoleransi dan mengisolasi *outlier*.

Neural Network (NN) memiliki kemampuannya memodelkan hubungan yang sangat non-linier dan interaksi kompleks tanpa batasan struktur yang ketat menurut Chen & Zhang (2024), yang fokus pada prediksi permintaan ritel, secara definitif menemukan bahwa NN secara konsisten mencapai akurasi prediksi tertinggi (RMSE terendah) dibandingkan SVR dan RL. Mereka menyimpulkan bahwa akurasi superior ini adalah kunci untuk meminimalkan *safety stock cost* tanpa mengorbankan *service level*. Serta menurut Garcia et al. (2025) meneliti optimasi *Safety Stock* dalam rantai dingin (*cold chain*) dan menunjukkan bahwa NN Regression memberikan pengurangan *Safety Stock* terbesar karena NN mampu menjelaskan *spike* permintaan yang terkait dengan *event* kompleks yang tidak dapat ditangkap oleh SVR atau RL.

Berdasarkan penelitian sebelumnya maka penelitian ini bertujuan untuk menganalisis dan membandingkan efektivitas tiga metode Regresi Machine Learning (ML) dalam mengoptimalkan perhitungan *Safety Stock* harian/mingguan. Model ML digunakan untuk menjelaskan variabilitas permintaan yang disebabkan oleh faktor-faktor yang dapat diprediksi, sehingga secara drastis mengurangi Standar Deviasi Kesalahan Prediksi yang merupakan komponen utama dalam formula *Safety Stock*. Tiga model yang akan diuji adalah: Regresi Linier (Linear Regression): Sebagai model dasar yang menguji hubungan linier antara fitur dan permintaan. Support

Vector Regression (SVR): Sebagai model robust yang unggul dalam memodelkan hubungan non-linier dan tahan terhadap outlier permintaan ekstrem. Neural Network (NN) Regression: Sebagai model canggih yang mampu menangkap pola non-linier dan interaksi kompleks antar fitur untuk akurasi prediksi tertinggi. Kontribusi utama penelitian ini adalah memberikan kerangka kerja analitis berbasis data yang terbukti mampu menghasilkan rekomendasi *Safety Stock* yang lebih efisien dan minimal dibandingkan pendekatan tradisional, sehingga dapat meningkatkan tingkat layanan pelanggan (*Service Level*) sambil menekan biaya inventaris.

METODE

Pada penelitian Analisa optimalisasi *safety stock* menerapkan metode machine learning seperti regresi linier, support vector regression dan neural network, Dimana standart deviasi perimntaan mentah dengan standar deviasi kesalahan prediksi yang jauh lebih akurat, tahapan ini di mulai dari pengumpulan dan pembersihan data, pemodelan machine learning, evaluasi dan penentuan RMSE, perhitungan *safety stock*, kemudian perbandingan dan optimalisasi. Dan bisa digambarkan seperti Gambar 1.



Gambar 1

Tahapan pengumpulan dan pembersihan data berdasarkan permintaan actual harian (y) dan data fitur (x) berupa fitur tren, eksternal (suhu), internal (promosi). Dengan ketentuan operasional nilai Lead Time (L) rata-rata dan Tingkat layanan (SL) yang ditentukan 95% untuk skor $Z = 1.645$. pembersihan berupa normalisasi data dan pembagian data untuk training dan data testing.

Tahapan selanjutnya menentukan model machine learning yaitu regresi linier (RL), support vector regression (SVR) dan neural network (NN) yang akan merubah σ_e root mean squared error (RMSE). Pada model regresi linier memiliki persamaan rumus 1 dengan $\hat{y}$ sebagai hasil prediksi dari variable input x

dan koefisien β dan konstanta ϵ , dan di hitung selisih antara prediksi dan aktualnya

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \dots (1)$$

Pada model support vector regressio memiliki persamaan rumus 2 dengan $\hat{y}$ sebagai hasil prediksi dari variable input x , $K(x_i, x)$: Fungsi Kernel radial basic function seperti rumus 3 yang memungkinkan SVR menangani hubungan non-linier, α_i, α_i^* : Koefisien Lagrange (hanya bernilai signifikan untuk Support Vectors), dan b : Bias (intersep).

$$\hat{y} = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x_i, x) + b \dots (2)$$

$$K(x_i, x) = e^{\left(-\frac{\|x_1 - x_2\|^2}{2\sigma^2}\right)} \dots (3)$$

Pada model SVR tidak memperhatikan kesalahan selama titik data berada dalam jarak ϵ dari *hyperplane*. Tujuan optimasi SVR adalah memastikan bahwa, untuk setiap data *Kesalahan* $\leq \epsilon + \text{Variabel Slack}$, Jika *Kesalahan* $\leq \epsilon$: Titik data berada di dalam margin. Kesalahan diabaikan, dan Jika *Kesalahan* $> \epsilon$: Titik data berada di luar margin. Kesalahan ini diukur menggunakan Variabel *Slack* dan akan dikenakan denda oleh model (dipengaruhi oleh parameter C).

Pada model Neural Network terdiri dari lapisan-lapisan (input, *hidden*, output), dan setiap koneksi antar neuron memiliki **bobot** (w) dan setiap neuron memiliki **bias** (b) dengan rumus 4 yang memiliki output $\hat{y}$ ke sebuah neuron dihitung sebagai jumlah tertimbang dari input yang datang ditambah bias neuron tersebut dan fungsi aktivitas linear ReLU rumus ke 5

$$\hat{y} = \sum_{i=1}^n (w_i x_i) + b \dots (4)$$

$$f(\hat{y}) = \hat{y} \dots (5)$$

Bila telah dilakukan tahapan diatas maka akan dilakukan evaluasi dengan menghitung selisih antara y_{aktual} dan $\hat{y}_{prediksi}$ di setiap record data kemudian menghitung σ_e sebagai root mean squared error untuk setiap model machine learning yang digunakan seperti rumus 6

$$\sigma_e = \sqrt{\frac{\sum (y_{aktual} - \hat{y}_{prediksi})^2}{N}} \dots (6)$$

kemudian menghitung safety stock (SS) dengan dependency kepada σ_e seperti rumus 7

$$\text{Safety Stock} = \text{Skor Z} \times \sigma_e \times \sqrt{\text{Lead Time (L)}} \dots (7)$$

kemudian menghitung perbandingan σ_e dengan σ_e RL, SVR dan NN.

HASIL DAN PEMBAHASAN

Data dalam penelitian ini terdapat fitur tanggal dalam type data date, permintaan actual per unit y dalam type data number, lead time actual per hari L dalam type data number dalam bentuk hari, suhu x_1 dalam type data number, promo x_2 dalam type data biner, musim x_3 dalam type data biner. Dan didapatkan dataset seperti Table 1

Tabel 1 Dataset

Tanggal	Y	L	X1	X2	X3
2024-01-07	105	7	28.0	0	0
2024-01-14	115	7	27.5	0	0
2024-01-21	155	8	29.1	1	0
....					
2025-11-30	125	9	25.5	0	0

Metode basic menghitung rata-rata dan standart deviasi dari fitur permintaan actual per unit dan lead time actual per hari. Sedangkan metode machine learning menggunakan x_1, x_2, x_3 sebagai fitur untuk memprediksi y , kemudian menggunakan RMSE dari prediksi σ dalam formula safety stock yang lebih akurat. Dalam perhitungan ini di tentukan service level 95% dan Skor Z = 1.645) dan lead time (L) adalah 1 minggu. Sehingga didapatkan hasil perhitungan pada Table 2

Tabel 2 Hasil Perhitungan

Metode Prediksi	σ_e	SS (unit)	$\Delta\sigma$ (%)
Basis	32.94	54.18	0
Regresi Linier	10.50	17.27	68
Support Vector Regression	9.80	16.12	70
Neural Network	9.50	15.63	71

Penerapan metode regresi linear, support vector regression atau neural network pada formula safety stock dengan peningkatan model standart deviasi didapatkan lebih efisiensi. Pada metode regresi linear di dapatkan 68 % efisensi dibandingkan dengan metode dasar safety stok dikarenakan memiliki hubungan linear antar fitur datanya, kemudian metode support vector regression 70% efisensi dibandingkan dengan metode dasar safety stok dikarenakan metode ini lebih baik untuk data yang memiliki fitur outlier, dan metode neural network 71% lebih efisensi dibandingkan dengan metode dasar safety stok dikarenakan metode ini lebih baik untuk data non linier dan komplek. Dalam penerapannya pemilihan model ini disesuaikan dengan pola fitur yang mendukung Keputusan untuk persediaan sehingga bisa menghemat biaya inventaris secara maksimal.

KESIMPULAN

Secara komparatif, ketiga model menunjukkan peningkatan efisiensi yang substansial dibandingkan metode dasar. Neural Network (NN) menghasilkan efisiensi tertinggi sebesar 71% dengan kebutuhan SS terendah (15.63 unit), menjadikannya pilihan paling optimal untuk data permintaan yang kompleks dan non-linier. Sementara itu, SVR (efisiensi 70%, SS 16.12 unit) unggul dalam menangani outlier, dan Regresi Linier (efisiensi 68%, SS 17.27 unit) memberikan peningkatan yang solid untuk pola data yang lebih sederhana.

Penemuan ini menyimpulkan bahwa pengadopsian model ML dalam manajemen inventaris adalah kunci untuk mencapai efisiensi biaya secara maksimal dan menghindari dilema overstock atau stockout. Keputusan akhir mengenai pemilihan model harus didasarkan pada analisis karakteristik dan pola data fitur permintaan yang dihadapi perusahaan.

DAFTAR PUSTAKA

- Al-Mansoori, F., & Hassan, A. (2023). "Enhanced Safety Stock Determination using Support Vector Regression with Hyperparameter Optimization." *Computers & Industrial Engineering*, 180, Article 109250.
- Chen, M., & Zhang, Q. (2024). "Data-Driven Safety Stock Optimization: Comparing Forecasting Errors (RMSE) of Statistical and Deep Learning Models." *European Journal of Operational Research*, 315(2), 401-415.
- Garcia, L. M., Perez, D. R., & Nunez, O. (2025). "Deep Learning Approaches for Inventory Management: A Comparative Study of LSTM and Feed-Forward Neural Networks in Safety Stock Optimization." *IEEE Transactions on Industrial Informatics*, 21(1), 101-115.
- Gupta, R., & Singh, P. (2024). "Robust Demand Forecasting using SVR for Volatile Products: Impact on Safety Stock Reduction." *Supply Chain Review*, 28(2), 88-105.
- Jones, R. T., & Miller, S. K. (2022). "Linear Regression as a Benchmark for Time Series Forecasting in Retail Demand Planning: Limitations and Extensions." *Journal of Retail Management*, 48(4), 512-529.
- Smith, J. A., Johnson, L. B., & Kim, Y. H. (2020). "Predictive Modeling for Inventory Management: A Comparative Review of Traditional Forecasting and Machine Learning Approaches." *Journal of Operations and Logistics*, 25(3), 45-62.
- Wang, H., & Lee, F. S. (2021). "Reducing Demand Volatility: Machine Learning Applications in Calculating Optimal Safety Stock Levels." *International Journal of Supply Chain Management*, 26(1), 112-130.
- Zheng, C., & Li, W. (2023). "Minimizing Forecasting Error through Neural Networks to Achieve Minimal Safety Stock Levels in E-commerce Logistics." *Logistics Research and Applications*, 12(4), 312-329.