

Pengembangan Model Prediksi Permintaan Baby Product pada Merchant Shopee Menggunakan Support Vector Regression

Echa Karlinda Devi, Noviyanti Santoso, Heri Kuswanto

Institut Teknologi Sepuluh Nopember, Indonesia

Email: echa.karlinda@gmail.com, noviyanti.santoso@its.ac.id, heri.kuswanto@its.ac.id

Keywords:

Demand Forecasting, Grid Search, Inventory Planning, Machine Learning, Support Vector Regression (SVR)

Abstract

The Indonesian diaper and baby milk markets are showing significant growth trends, with projected values reaching USD 2.39 billion and USD 5.35 billion, respectively, by 2029. This study aims to build an accurate demand prediction model using the Support Vector Regression (SVR) method to anticipate spikes or declines in demand and provide recommendations for effective inventory management and marketing strategies. The variables used include transactional features (SKU, category, price, various types of discounts/vouchers, Shopee coins, and shipping discounts) and external factors (national holidays and Shopee events). Data is processed through cleaning, feature engineering, and normalization stages, then a comparison test is conducted where the first trial uses training data (70%) and test data (30%), then the second trial is conducted using training data (80%) and test data (20%). Model optimization is carried out using the RBF kernel with the Grid Search technique to find the most optimal hyperparameters. The results showed that the model in the second trial using a comparison of training data (80%) and test data (20%) produced better results, being able to explain approximately 52% of the variability in demand data with an MAE value of 1.34 units and an RMSE of 3.73 units. In conclusion, this model is quite reliable in capturing general patterns and trends in demand fluctuations in volatile markets. The implementation of the model in the form of an interactive dashboard provides practical benefits for merchants to simulate promotional scenarios and optimize stock management, thereby increasing operational efficiency and long-term business profitability.

Kata Kunci:

Grid Search, Perencanaan Stok, Prediksi Permintaan, Machine Learning, Support Vector Regression (SVR).

Abstrak

Pasar popok dan susu bayi di Indonesia menunjukkan tren pertumbuhan yang signifikan dengan proyeksi nilai masing-masing mencapai USD 2,39 miliar dan USD 5,35 miliar pada tahun 2029. Penelitian ini bertujuan untuk membangun model prediksi permintaan yang akurat menggunakan metode Support Vector Regression (SVR) guna mengantisipasi lonjakan atau penurunan permintaan serta memberikan rekomendasi strategi manajemen inventori dan pemasaran yang efektif. Variabel yang digunakan mencakup fitur transaksional (SKU, kategori, harga, berbagai jenis potongan harga/voucher, koin Shopee, dan diskon ongkir) serta faktor eksternal (hari libur nasional dan event Shopee). Data diproses melalui tahap cleaning, feature engineering, dan normalisasi,

kemudian dilakukan uji perbandingan dimana uji coba pertama menggunakan data latih (70%) dan data uji (30%), lalu dilakukan uji coba kedua dengan menggunakan data latih (80%) dan data uji (20%). Optimasi model dilakukan menggunakan kernel RBF dengan teknik Grid Search untuk menemukan hyperparameter paling optimal. Hasil penelitian menunjukkan bahwa model pada uji coba kedua menggunakan perbandingan data latih (80%) dan data uji (20%) menghasilkan hasil yang lebih baik dimana mampu menjelaskan sekitar 52% variabilitas data permintaan dengan nilai MAE sebesar 1,34 unit dan RMSE sebesar 3,73 unit. Kesimpulannya, model ini cukup andal dalam menangkap pola umum dan tren fluktuasi permintaan di pasar yang volatil. Implementasi model dalam bentuk dashboard interaktif memberikan manfaat praktis bagi merchant untuk melakukan simulasi skenario promosi dan mengoptimalkan pengelolaan stok, sehingga dapat meningkatkan efisiensi operasional dan profitabilitas bisnis jangka panjang.

PENDAHULUAN

Pasar popok dan susu bayi di Indonesia menunjukkan tren pertumbuhan yang signifikan dan berkelanjutan, menempatkan posisinya sebagai segmen pasar yang diprediksi akan terus berkembang. Data dari (Statista, 2024) mengindikasikan proyeksi peningkatan penjualan popok bayi nasional dari USD 1,27 miliar pada tahun 2018 menjadi USD 2,39 miliar pada tahun 2029. Sedangkan untuk penjualan susu bayi juga mengalami tren peningkatan dari USD 2,76 miliar pada tahun 2018 diproyeksi akan mencapai USD 5,35 miliar pada tahun 2029 (Cameron & Windmeijer, 1997; Chowdhury et al., 2025; Cortes & Vapnik, 1995). Tren peningkatan ini mencerminkan stabilitas dan potensi pertumbuhan jangka panjang dalam pasar ini, dengan hanya sedikit penurunan pada popok bayi yang tercatat pada tahun 2020, kemungkinan besar dipengaruhi oleh dinamika pasar (de Lange et al., 2022; Faber, 1999; Fan et al., 2023). Pertumbuhan ini dapat didorong oleh berbagai faktor, seperti meningkatnya kesadaran orang tua, munculnya variasi produk premium, pengaruh media sosial, intervensi pemerintah, serta perhatian terhadap kesehatan dan kesejahteraan bayi (Febriani & Fatichah, 2024; Febrianti & Hasan, 2022; Gahlot & Rani, 2023).

Data penjualan dari sebuah merchant shopee yang menjadi objek penelitian menunjukkan pola permintaan yang sangat fluktuatif, terjadi peningkatan dari Rp 30,1 juta pada kuartal 1 tahun 2023 menjadi Rp 267 juta pada kuartal 4 tahun 2023, lalu melonjak ke Rp 576 juta di kuartal 1 tahun 2024 sebelum berfluktuasi kembali di periode akhir 2024 hingga menyentuh Rp 265 juta di kuartal ke 4. Lonjakan mendadak dan penurunan drastis tersebut mengindikasikan ketidakpastian permintaan. Faktor-faktor eksternal seperti promosi besar atau tren pasar yang tak terduga kerap memicu puncak permintaan tiba-tiba (Liu et al., 2023; Ma et al., 2021; Palgunadi et al., 2024; Prayitno, 2023). Oleh karena itu, model prediksi permintaan sangat dibutuhkan, untuk mengintegrasikan hasil prediksi permintaan dengan strategi pemasaran model tersebut harus mempertimbangkan variabel-variabel seperti perilaku konsumen dan analisis tren pasar untuk meningkatkan akurasi prediksi dan mengoptimalkan manajemen persediaan (Tello et al., 2022; Vinny et al., 2023). Menurut (Were et al., 2015; Zafira et al., 2024) prediksi permintaan yang akurat dapat meningkatkan efisiensi pengelolaan persediaan barang sehingga dapat menghindari kelebihan maupun kekurangan stok.

Bidang kajian mengenai prediksi permintaan telah mengalami evolusi yang signifikan dari metode statistik tradisional ke teknik pembelajaran mesin (Machine Learning) dan pembelajaran mendalam (Deep Learning) (Punia & Shankar, 2022). Evolusi ini didorong oleh kebutuhan akan akurasi yang lebih tinggi dan kemampuan adaptasi terhadap data yang kompleks dan dinamis (Gopagani et al., 2020; Guo et al., 2021; Güven & Şimşir, 2020; Hediarti, 2019). Metode tradisional seperti ARIMA dan Exponential Smoothing seringkali kesulitan menangani pasar yang volatil serta hubungan yang kompleks dan non-linear, dan tidak dapat memproses data berdimensi tinggi secara efisien (Svetunkov et al., 2022). Sebaliknya, model Machine Learning dapat belajar pola dari kumpulan data yang luas, meningkatkan akurasi, dan beradaptasi dengan dinamika pasar (Gopagani et al., 2020). Dengan demikian, transisi dari metode tradisional ke Machine Learning dan Deep Learning membawa inovasi baru dalam meningkatkan ketepatan prediksi permintaan di berbagai sector (Holst & Thyregod, 1999; Kilimci et al., 2019; Lestari & Dwijayanti, 2022; Li & Zhang, 2022).

Beberapa penelitian sebelumnya telah dilakukan untuk meningkatkan akurasi prediksi permintaan dalam konteks e-commerce (Qi et al., 2020; Raju et al., 2022; Robeson & Willmott, 2023; Sheehan et al., 2019). (Zhang & O'Donnell, 2020) mengembangkan model hibrida Word2Vec dan ConvLSTM yang terbukti menghasilkan akurasi lebih tinggi dibanding LSTM dan LGBM, menunjukkan keunggulan pendekatan deep learning dalam menangani data penjualan kompleks. (Y. Wang & Zhang, 2023) memanfaatkan SVR multivariat dengan input fitur produk dan sentimen ulasan pelanggan, serta mengoptimasi parameter menggunakan Particle Swarm Optimization, menghasilkan kesalahan prediksi paling rendah dibandingkan variasi SVR lainnya. (Ahmadov & Helo, 2023) mengusulkan model ensemble yang menggabungkan Deep Belief Networks (DBN) dan SVR, di mana output dari beberapa DBN dijadikan input untuk SVR, terbukti mampu meningkatkan performa prediksi dibanding algoritma individual. Sementara itu, (C. Wang & Wang, 2025) mengembangkan kerangka hybrid ARIMA-LSTM yang efektif untuk memprediksi permintaan berdasarkan kestabilan dan volatilitas data, menyoroti keunggulan pendekatan kombinasi statistik dan deep learning.

Meskipun kebutuhan akan prediksi permintaan yang akurat dalam e-commerce dan beragamnya teknik pembelajaran mesin yang telah diterapkan, namun masih terdapat celah dimana masih sedikit studi yang secara khusus mengembangkan dan mengevaluasi model prediksi permintaan untuk produk susu dan popok bayi di e-commerce dengan menggunakan metode Support Vector Regression (SVR). Apalagi dengan mempertimbangkan variabel-variabel seperti event promo dan hari libur nasional. SVR dipilih karena kemampuannya menangani hubungan non-linear dan kepekaannya yang rendah terhadap outlier, sehingga cocok untuk skenario permintaan dengan banyak gangguan dan fluktuasi (Ma et al., 2021). Dengan menggunakan SVR, model dapat memberikan prediksi yang lebih stabil dan akurat, terutama dalam konteks data yang kompleks dan tidak teratur. Sehingga hasilnya diharapkan membantu pengambilan keputusan dalam manajemen stok dan promosi, misalnya dengan memastikan stok optimal saat ada promo besar dan menghindari kelebihan stok saat permintaan turun drastis.

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah dalam penelitian ini adalah bagaimana memodelkan serta memprediksi permintaan produk agar pelaku bisnis dapat mengantisipasi lonjakan maupun penurunan permintaan, serta bagaimana hasil prediksi tersebut dapat dimanfaatkan oleh pihak merchant dalam merancang strategi pemasaran,

pengelolaan inventori, dan pengambilan keputusan promosi secara lebih efektif dan efisien. Sejalan dengan rumusan masalah tersebut, penelitian ini bertujuan untuk membangun model prediksi permintaan produk menggunakan metode Support Vector Regression (SVR) berdasarkan data historis transaksi sehingga perencanaan persediaan dapat dilakukan dengan lebih akurat, serta memberikan rekomendasi strategi berbasis data bagi pengelola merchant dalam merumuskan strategi pemasaran, promosi, dan pengelolaan stok yang lebih tepat. Secara teoritis, penelitian ini memberikan kontribusi dalam pengembangan kajian prediksi permintaan berbasis machine learning, khususnya melalui penerapan SVR dalam konteks e-commerce, sehingga dapat memperluas pemahaman mengenai model prediksi non-linear yang mempertimbangkan variabel seperti event promosi dan hari libur nasional serta menjadi dasar bagi penelitian lanjutan dalam pengelolaan rantai pasok digital. Secara praktis, hasil penelitian ini diharapkan dapat dimanfaatkan oleh pelaku bisnis online untuk meningkatkan akurasi prediksi permintaan sehingga mendukung perencanaan stok, strategi promosi, dan kebijakan pemasaran yang lebih adaptif dalam menghadapi fluktuasi permintaan serta dinamika pasar e-commerce. Namun demikian, penelitian ini memiliki beberapa batasan, yaitu data yang digunakan hanya mencakup periode Januari 2023 hingga Desember 2024 dan berasal dari satu toko online yang menjual produk baby diapers di platform marketplace, sehingga hasil penelitian belum tentu mewakili seluruh kategori produk atau toko lain di e-commerce, serta sumber data diperoleh secara internal melalui dashboard Shopee Seller yang hanya mencakup data transaksional kuantitatif tanpa mempertimbangkan faktor eksternal seperti ulasan pelanggan atau strategi kompetitor.

METODE PENELITIAN

Jenis Penelitian

Penelitian ini akan menggunakan pendekatan kuantitatif dengan desain penelitian kausal-komparatif dan prediktif. Pendekatan kuantitatif dipilih karena memungkinkan pengujian hipotesis, analisis hubungan antar variabel, dan pembangunan model peramalan berdasarkan data numerik yang terukur secara objektif. Desain kausal-komparatif akan digunakan untuk mengidentifikasi dan menganalisis faktor-faktor yang mempengaruhi jumlah produk terjual, sementara desain prediktif akan diterapkan untuk membangun model peramalan permintaan penjualan.

Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa data historis penjualan sebuah toko online, yang mencakup informasi seperti kode SKU, kategori, harga awal, potongan harga, potongan voucher dan potongan koin shopee, diskon ongkos kirim, jumlah barang terjual, serta atribut even promo dan libur nasional. Data ini diperoleh dari sistem dashboard penjualan dalam format file CSV, dengan cakupan periode waktu dari Januari 2023 hingga Desember 2024 (24 bulan).

Variabel Penelitian dan Struktur Data

Penelitian ini menggunakan dua jenis variabel, yaitu variabel dependen dan variabel independen, yang masing-masing memiliki peran penting dalam membangun model prediksi permintaan. Variabel dependen merupakan target yang ingin diprediksi, sedangkan variabel independen merupakan faktor-faktor yang diasumsikan memengaruhi jumlah penjualan. Penjelasan lebih lengkapnya disajikan pada Tabel 1 sebagai berikut:

Tabel 1 Variabel Penelitian dan Definisi Operasional

Kode	Nama Variabel	Definisi Operasional	Skala Data
Variabel Dependen			
Y	Jumlah Terjual	Jumlah unit suatu produk (SKU) yang terjual pada tanggal tertentu	Rasio
Variabel Independen			
X1	SKU	Kode unik yang digunakan untuk mengidentifikasi setiap produk dalam sistem inventori toko online yang terdiri dari 128 item dengan jenis dan nama yang berbeda.	Nominal
X2	Kategori	Pengelompokan produk berdasarkan jenis atau fungsi utama produk, terdiri dari 5 kategori yaitu popok bayi, popok dewasa, susu, tisu dan produk pelengkap lainnya.	Nominal
X3	Harga Awal	Harga jual produk sebelum adanya potongan atau promosi yang berlaku.	Rasio
X4	Potongan Harga	Potongan langsung yang diberikan terhadap harga awal produk, biasanya dalam bentuk diskon.	Rasio
X5	Voucher Penjual	Nilai diskon tambahan yang diberikan oleh penjual (merchant) melalui voucher yang dapat digunakan pembeli.	Rasio
X6	Voucher Shopee	Nilai potongan harga yang diberikan oleh platform Shopee dalam bentuk voucher platform.	Rasio
X7	Potongan Koin Shopee	Nilai pengurangan dari total harga menggunakan koin Shopee yang dikumpulkan oleh pembeli.	Rasio
X8	Diskon Ongkos Kirim	Nilai potongan biaya pengiriman yang diberikan oleh Shopee (dalam Rupiah)	Rasio
X9	Even Libur Nasional	Indikator yang menunjukkan apakah hari tersebut merupakan hari libur nasional, ada 2 kategori jika libur maka diberi flag Ya dan Tidak jika pada hari tersebut memang tidak libur.	Nominal
X10	Even Shopee	Indikator yang menunjukkan apakah pada hari tersebut ada event promo Shopee, dengan 2 kategori Ya jika pada hari transaksi ada even promo dan Tidak jika tidak ada even.	Nominal

Dataset terdiri dari 18.249 baris (observasi) dan 10 kolom (fitur). Setiap baris merepresentasikan penjualan dari satu produk (SKU) pada tanggal tertentu. Adapun struktur data yang digunakan dalam penelitian ini disajikan dalam Tabel 3.2 berikut.

Tabel 2 Struktur Data

Y	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀
Y ₁	X _{1,1}	X _{1,2}	X _{1,3}	X _{1,4}	X _{1,5}	X _{1,6}	X _{1,7}	X _{1,8}	X _{1,9}	X _{1,10}
Y ₂	X _{2,1}	X _{2,2}	X _{2,3}	X _{2,4}	X _{2,5}	X _{2,6}	X _{2,7}	X _{2,8}	X _{2,9}	X _{2,10}
Y ₃	X _{3,1}	X _{3,2}	X _{3,3}	X _{3,4}	X _{3,5}	X _{3,6}	X _{3,7}	X _{3,8}	X _{3,9}	X _{3,10}
...	...	...	...	...	...	...	...	...	...	...
Y _{18.249}	X _{18.249,1}	X _{18.249,2}	X _{18.249,3}	X _{18.249,4}	X _{18.249,5}	X _{18.249,6}	X _{18.249,7}	X _{18.249,8}	X _{18.249,9}	X _{18.249,10}

Pembuatan Model Prediksi Permintaan dengan SVR

Pembuatan model prediksi permintaan akan dilakukan menggunakan algoritma Support Vector Regression (SVR). SVR dipilih karena kemampuannya dalam menangani hubungan non-linear dan ketahanan terhadap outlier, yang relevan dengan fluktuasi permintaan produk popok bayi di e-commerce. Tahapan dalam pembuatan model ini akan meliputi:

1. Pra-pemrosesan Data

Tahap ini bertujuan untuk menyiapkan data agar siap digunakan dalam pelatihan model SVR. Data penjualan historis dari periode Januari 2023 hingga Desember 2024 akan diolah dengan langkah-langkah berikut:

- a. Pengumpulan Data: Data akan diambil dari dashboard Shopee Seller toko online objek penelitian. Data yang dikumpulkan meliputi informasi transaksi harian seperti jumlah penjualan produk, harga awal, potongan harga, potongan voucher, potongan koin shopee, diskon ongkos kirim, jenis event promosi yang sedang berlangsung, dan informasi mengenai hari libur nasional.
- b. Pembersihan Data: Penanganan nilai yang hilang (missing values): Jika terdapat nilai yang hilang, akan dilakukan imputasi atau penghapusan data, tergantung pada proporsi dan signifikansi data yang hilang. Identifikasi dan penanganan outlier: Data outlier yang signifikan, seperti lonjakan permintaan yang tidak biasa, akan dianalisis dan ditangani agar tidak mengganggu performa model.
- c. Rekayasa Fitur (Feature Engineering): Fitur kategorik seperti SKU, Kategori, Event Promosi, dan Hari Libur Nasional akan diubah ke format numerik menggunakan teknik encoding yang sesuai, seperti One-Hot Encoding atau Label Encoding, agar dapat diproses oleh algoritma SVR.
- d. Normalisasi/Standardisasi Data: Fitur numerik akan dinormalisasi atau distandardisasi (misalnya, menggunakan Min-Max Scaling atau Z-score Standardization) untuk memastikan bahwa semua fitur memiliki skala yang sama, mencegah dominasi fitur dengan rentang nilai yang lebih besar, dan meningkatkan kinerja SVR.

2. Pembagian Data

Data yang telah diproses akan dibagi menjadi dua set:

- a. Data Pelatihan (Training Data): Digunakan untuk melatih model SVR. Proporsi data pelatihan umumnya 70-80% dari total data.
- b. Data Pengujian (Testing Data): Digunakan untuk mengevaluasi kinerja model yang telah dilatih pada data yang belum pernah dilihat sebelumnya. Proporsi data pengujian umumnya 20-30% dari total data. Pembagian data akan dilakukan secara kronologis untuk mempertahankan sifat time-series data, sehingga data yang lebih lama digunakan untuk pelatihan dan data yang lebih baru untuk pengujian.

3. Konfigurasi dan Pelatihan Model SVR

Pada tahap ini, model SVR akan dikonfigurasi dan dilatih menggunakan data pelatihan:

- a. Pemilihan Kernel: SVR menawarkan beberapa fungsi kernel (linear, polynomial, Radial Basis Function/RBF). Akan dilakukan eksperimen dengan berbagai kernel, dengan fokus awal pada kernel RBF yang seringkali efektif untuk menangani hubungan non-linear.
- b. Penentuan Hyperparameter: Hyperparameter kunci SVR seperti C (parameter regularisasi), ϵ (epsilon-tube), dan γ (koefisien kernel untuk RBF) akan dioptimalkan. Metode Grid Search atau Random Search dengan validasi silang (cross-validation) akan digunakan untuk menemukan kombinasi hiperparameter terbaik yang memberikan kinerja optimal pada data pelatihan.
- c. Pelatihan Model: Model SVR akan dilatih menggunakan data pelatihan yang telah diproses dan hiperparameter yang optimal. Proses pelatihan akan melibatkan penyesuaian bobot dan bias model untuk meminimalkan error prediksi.

4. Evaluasi Model

Evaluasi model dilakukan untuk menilai seberapa baik model SVR memprediksi permintaan pada data yang tidak terlihat. Metrik evaluasi yang akan digunakan meliputi:

- a. Mean Absolute Error (MAE): Mengukur rata-rata kesalahan absolut antara nilai prediksi dan nilai aktual.
- b. Mean Squared Error (MSE): mengukur rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual.
- c. Root Mean Squared Error (RMSE): Mengukur akar kuadrat dari rata-rata kuadrat kesalahan, memberikan bobot lebih pada kesalahan besar.
- d. R-squared (R²): Mengukur proporsi varians dalam variabel dependen yang dapat diprediksi dari variabel independen.

Implikasi Manajerial

Bagian ini menguraikan secara rinci bagaimana hasil dari model prediksi permintaan berbasis Support Vector Regression (SVR) dan rekomendasi strategis yang dihasilkan dapat diimplementasikan dan dimanfaatkan secara nyata oleh pengelola toko online untuk meningkatkan efisiensi operasional dan profitabilitas. Implikasi manajerial ini akan dibedah per area fungsional utama, meliputi Manajemen Inventori, Strategi Pemasaran dan Promosi, serta Pengambilan Keputusan Bisnis Secara Menyeluruh.

1. Implikasi Terhadap Manajemen Inventori

Model prediksi permintaan yang akurat akan menjadi tulang punggung dalam optimasi manajemen inventori. Ini memungkinkan toko online untuk beralih dari pendekatan reaktif menjadi proaktif dalam pengelolaan stok.

- a. Optimasi Tingkat Stok Minimum dan Maksimum:
 - 1) Perencanaan Restock yang Tepat Waktu: Berdasarkan prediksi permintaan harian atau mingguan, pengelola dapat menetapkan ambang batas stok minimum (reorder point) yang lebih dinamis. Misalnya, jika model memprediksi lonjakan permintaan 2 minggu ke depan (misalnya menjelang 10.10 atau even tertentu), purchase order ke supplier dapat diajukan lebih awal dan dengan volume yang lebih besar untuk menghindari kehabisan stok.
 - 2) Menghindari Overstock dan Understock: Prediksi akurat akan mengurangi insiden overstock (kelebihan stok) yang mengikat modal dan membebani biaya penyimpanan, serta understock (kekurangan stok) yang berujung pada kehilangan penjualan dan potensi kekecewaan pelanggan.
 - 3) Penyesuaian Kapasitas Gudang: Data prediksi dapat digunakan untuk memperkirakan kebutuhan ruang gudang di masa mendatang, terutama saat memprediksi volume penjualan yang tinggi, memungkinkan alokasi ruang yang lebih efisien atau bahkan pertimbangan untuk perluasan kapasitas sementara.
- b. Manajemen Siklus Hidup Produk:
 - 1) Pengenalan Produk Baru: Untuk produk popok bayi yang baru diluncurkan, prediksi dapat dimulai dengan data historis produk serupa atau tren pasar umum, lalu disesuaikan secara cepat seiring dengan akumulasi data penjualan awal, memungkinkan penentuan volume stok awal yang lebih rasional.
 - 2) Pengelolaan Produk Lama/Diskontinu: Model dapat membantu mengidentifikasi penurunan permintaan pada varian produk tertentu, memicu keputusan untuk memberlakukan promosi penghabisan stok (clearance sale) sebelum produk menjadi usang atau tidak laku sama sekali.

c. Pengurangan Biaya Operasional:

- 1) Efisiensi Pengadaan Barang: Dengan mengetahui volume permintaan yang diprediksi, negosiasi dengan supplier dapat dilakukan lebih efektif untuk mendapatkan harga terbaik dengan volume pesanan yang sesuai, serta mengoptimalkan frekuensi pengiriman untuk mengurangi biaya logistik per unit.
- 2) Meminimalkan Biaya Penyimpanan: Stok yang tidak terlalu banyak akan mengurangi risiko kerusakan atau kadaluarsa produk.

2. Implikasi Terhadap Strategi Pemasaran dan Promosi

Model prediksi permintaan bukan hanya alat operasional, tetapi juga senjata strategis untuk tim pemasaran. Data ini akan membantu merancang kampanye yang lebih targeted dan efektif.

a. Penetapan Harga Dinamis (Dynamic Pricing):

- 1) Mengoptimalkan Harga Jual: Saat model memprediksi peningkatan permintaan yang signifikan (misalnya, menjelang gaji), pengelola dapat mempertimbangkan untuk menahan diskon atau bahkan sedikit menaikkan harga untuk memaksimalkan margin keuntungan, tanpa terlalu khawatir kehilangan penjualan.
- 2) Strategi Diskon yang Berbasis Data: Sebaliknya, jika model memprediksi penurunan permintaan, diskon atau penawaran bundling dapat diaktifkan secara proaktif untuk merangsang pembelian dan mencegah penumpukan stok.

b. Perencanaan Kampanye Promosi dan Event:

- 1) Penjadwalan Promosi yang Efektif: Model akan membantu mengidentifikasi periode dimana promosi akan paling berdampak. Misalnya, jika model memprediksi permintaan rendah di luar event besar, flash sale atau promo voucher dapat dijalankan untuk menstimulasi penjualan.
- 2) Alokasi Anggaran Pemasaran: Data prediksi memungkinkan alokasi anggaran promosi yang lebih cerdas, mengalokasikan lebih banyak sumber daya ke periode dengan potensi penjualan tinggi yang teridentifikasi oleh model.
- 3) Personalisasi Penawaran: Meskipun belum menjadi fokus utama, ke depannya model dapat dikembangkan untuk memprediksi permintaan pada segmen pelanggan tertentu, memungkinkan penawaran promosi yang lebih personal.
- 4) Evaluasi Efektivitas Promosi: Dengan membandingkan penjualan aktual dengan prediksi baseline tanpa promosi, toko dapat secara kuantitatif mengukur dampak spesifik dari diskon, voucher, atau event tertentu.

3. Implikasi Terhadap Pengambilan Keputusan Bisnis Menyeluruh

Model prediksi permintaan yang komprehensif ini akan mendukung pengambilan keputusan strategis yang lebih luas, memberikan keunggulan kompetitif bagi toko online.

a. Peningkatan Kepuasan Pelanggan:

- 1) Ketersediaan Produk yang Konsisten: Dengan stok yang selalu tersedia saat dibutuhkan, pengalaman belanja pelanggan akan meningkat, mengurangi insiden pembatalan pesanan atau mencari toko lain.
- 2) Waktu Pengiriman yang Lebih Cepat: Ketersediaan stok di gudang memungkinkan proses pengemasan dan pengiriman yang lebih cepat, meningkatkan kepuasan pelanggan secara keseluruhan.

b. Peningkatan Profitabilitas Bisnis:

- 1) Optimalisasi Pendapatan: Dengan meminimalkan stockout dan memaksimalkan peluang penjualan saat permintaan tinggi, toko dapat mengoptimalkan pendapatan.
- 2) Pengurangan Biaya: Efisiensi dalam manajemen inventori dan promosi akan secara langsung berkontribusi pada penurunan biaya operasional, sehingga meningkatkan margin keuntungan bersih.

HASIL DAN PEMBAHASAN

Karakteristik Data

Sub-bab ini menyajikan gambaran umum mengenai karakteristik data yang digunakan dalam penelitian. Data yang dianalisis mencakup informasi mengenai SKU, kategori, harga awal, potongan harga, voucher penjual, voucher Shopee, potongan koin Shopee, diskon ongkos kirim, event Shopee, libur nasional serta jumlah produk yang terjual. Analisis univariat untuk variabel numerik diawali dengan penyajian statistik deskriptif, yang disajikan pada Tabel 4.1.


Tabel 3 Statistika Deskriptif

Variabel	N	Minimum	Maksimum	Mean	Std. Deviation
Harga Awal	18.249	4.000	440.000	54.416,22	49.492,84
Potongan Harga	18.249	0	25.500	88,20	1.378,01
Voucher Penjual	18.249	0	5.000	5,78	76,68
Voucher Shopee	18.249	0	208.800	5.212,89	9.882,09
Potongan Koin Shopee	18.249	0	290.475	1.975,81	9.437,28
Diskon Ongkos Kirim	18.249	0	250.501	16.172,50	12.478,73
Jumlah Terjual	18.249	1	85	3,09	5,21

Berdasarkan Tabel 3 dapat diamati bahwa rata-rata harga awal produk berada di angka Rp 54.416,22 dengan variasi yang tinggi yaitu standar deviasi Rp 49.492,84, menunjukkan rentang harga produk yang luas di mana terdapat sebagian kecil produk dengan harga jauh di atas rata-rata. Ditemukan bahwa promosi dalam bentuk potongan harga dan voucher penjual relatif jarang dimanfaatkan oleh konsumen median Rp 0, sementara voucher Shopee dan potongan koin Shopee, meskipun tidak digunakan pada sebagian besar transaksi, mampu memberikan penghematan yang substansial bagi pengguna yang memanfaatkannya, dimana maksimum mencapai Rp 208.800 hingga Rp 290.475. Secara signifikan, diskon ongkos kirim menjadi bentuk insentif yang paling dominan dan rata-rata nilainya tertinggi Rp 16.172,5, menunjukkan bahwa biaya pengiriman merupakan faktor krusial dalam keputusan pembelian konsumen. Mayoritas transaksi melibatkan pembelian 1-3 unit produk, meskipun terdapat pula kasus pembelian dalam skala besar (maksimum 85 unit), merefleksikan adanya segmen pembeli grosir. Data ini secara kolektif mengindikasikan bahwa subsidi ongkos kirim adalah strategi promosi paling efektif dalam mendorong transaksi, diikuti oleh insentif berupa voucher dan koin dari platform, sementara diskon langsung dari penjual memiliki dampak yang lebih terbatas.


Selanjutnya, distribusi variabel numerik direpresentasikan melalui histogram pada Gambar 1 hingga Gambar 5. Gambar 1 menampilkan distribusi harga awal produk dalam bentuk histogram. Terlihat jelas bahwa mayoritas produk memiliki harga awal di kisaran yang lebih rendah, dengan puncak distribusi yang sangat tinggi berada di bawah angka Rp 100.000. Setelah puncak utama ini, frekuensi harga menurun drastis, meskipun masih terdapat beberapa

puncak kecil atau penyebaran data yang menunjukkan adanya produk dengan harga di atas Rp 100.000, bahkan hingga mendekati Rp 400.000.



Gambar 1 Distribusi Harga Awal

Selanjutnya, Gambar 2 menyajikan distribusi dari empat jenis potongan harga dan voucher yang berbeda. Keempat histogram menunjukkan karakteristik sangat miring ke kanan (highly right-skewed) dengan sebagian besar frekuensi terkonsentrasi pada nilai nol atau mendekati nol, mengindikasikan bahwa mayoritas transaksi tidak mendapatkan potongan atau voucher tersebut, atau jika ada, nilainya sangat kecil.




Gambar 2 Distribusi Potongan Harga, Voucher Penjual dan Shopee

Distribusi Potongan Harga menunjukkan bahwa sebagian besar transaksi tidak memiliki potongan harga atau hanya potongan yang sangat kecil. Puncak distribusi sangat tajam di angka nol, dengan penurunan drastis seiring dengan meningkatnya nilai potongan. Distribusi Voucher Penjual, mirip dengan potongan harga, distribusi voucher penjual juga sangat terkonsentrasi di nilai nol, menekankan bahwa voucher dari penjual jarang digunakan atau nilainya sangat rendah dalam sebagian besar transaksi. Distribusi Voucher Shopee, meskipun masih sangat miring ke kanan, distribusi voucher Shopee menunjukkan sedikit penyebaran ke nilai yang lebih tinggi dibandingkan potongan harga dan voucher penjual. Ini mengindikasikan bahwa meskipun jarang digunakan secara luas, ketika digunakan, voucher Shopee dapat memiliki nilai


yang lebih signifikan. Terakhir pada distribusi Potongan Koin Shopee, juga sangat miring ke kanan, namun terlihat adanya ekor yang paling panjang ke arah nilai yang jauh lebih besar dibandingkan tiga distribusi lainnya. Ini menyiratkan bahwa meskipun frekuensinya rendah, potongan koin Shopee berpotensi memberikan pengurangan harga yang paling besar di antara keempat jenis insentif tersebut.

Gambar 4.3 menunjukkan distribusi diskon ongkos kirim yang signifikan berbeda dari jenis potongan harga lainnya, dengan sebagian besar transaksi memang menerima diskon ongkos kirim. Distribusi ini menunjukkan puncak frekuensi yang jelas di sekitar nilai diskon antara Rp 10.000 hingga Rp 20.000, mengindikasikan bahwa ini adalah rentang diskon ongkos kirim yang paling umum diberikan. Meskipun distribusi masih sedikit miring ke kanan, penyebarannya jauh lebih merata dibandingkan potongan harga atau voucher lainnya, yang cenderung terpusat di angka nol. Hal ini menggarisbawahi bahwa diskon ongkos kirim adalah insentif yang paling sering dan luas diterapkan, menjadikannya faktor kunci dalam mempengaruhi keputusan pembelian konsumen.




Gambar 3 Distribusi Diskon Ongkos Kirim

Jumlah Terjual, seperti yang ditunjukkan pada Gambar 4, memperlihatkan distribusi jumlah produk yang terjual per transaksi, yang didominasi oleh pembelian unit tunggal atau dalam jumlah sangat kecil. Puncak frekuensi tertinggi berada di angka 1 unit terjual, menunjukkan bahwa mayoritas transaksi adalah pembelian satu item produk. Seiring dengan peningkatan jumlah unit yang terjual, frekuensi transaksi menurun drastis, membentuk "ekor panjang" yang signifikan. Ini mengindikasikan bahwa meskipun ada beberapa transaksi dengan pembelian dalam jumlah sangat besar (hingga lebih dari 80 unit), kasus tersebut merupakan pengecualian. Dengan demikian, perilaku pembelian konsumen secara umum cenderung ke arah pembelian satuan dalam setiap transaksi.



Gambar 4 Distribusi Jumlah Terjual

Adapun distribusi dari variabel kategorik disajikan melalui *bar chart* pada Gambar 5 yang menunjukkan proporsi Kategori produk, di mana Popok Bayi mendominasi penjualan dengan proporsi hampir 58%, diikuti oleh Popok Dewasa (sekitar 25%). Kategori lain seperti Susu Bayi, Tisu, dan Others memiliki proporsi yang jauh lebih kecil.



Gambar 5 Distribusi Variabel Kategorik

Proporsi Libur Nasional mengindikasikan bahwa mayoritas transaksi (sekitar 94%) terjadi pada hari yang bukan merupakan libur nasional, menunjukkan bahwa data didominasi oleh transaksi pada hari kerja atau hari-hari biasa. Terakhir, proporsi transaksi yang tidak terjadi selama Even Shopee lebih tinggi (sekitar 72%) dibandingkan dengan yang terjadi selama Even Shopee (sekitar 28%).

Identifikasi distribusi yang sangat miring (*skewed*) pada beberapa variabel numerik dan keberadaan *outlier*, serta dominansi kategori tertentu pada variabel kategorikal, akan menjadi pertimbangan krusial dalam tahap pra-pemrosesan data selanjutnya. Langkah-langkah seperti transformasi data untuk mengurangi *skewness* atau penanganan *outlier* mungkin diperlukan untuk memastikan model Support Vector Regression (SVR) dapat bekerja secara optimal dalam memprediksi Jumlah Terjual.



Gambar 6 Matriks Korelasi

Berdasarkan matriks korelasi antar fitur numerik pada Gambar 6, dapat diketahui bahwa sebagian besar variabel independen memiliki hubungan linear yang lemah terhadap variabel *Jumlah Terjual*. Variabel *Diskon Ongkos Kirim* menunjukkan korelasi positif tertinggi dengan *Jumlah Terjual* ($r = 0,34$), yang mengindikasikan bahwa pemberian diskon ongkos kirim cenderung diikuti oleh peningkatan volume penjualan. Sementara itu, *Potongan Koin Shopee* memiliki korelasi positif lemah ($r = 0,16$), yang menunjukkan pengaruh terbatas terhadap peningkatan penjualan.

Sebaliknya, *Harga Awal* menunjukkan korelasi negatif lemah terhadap *Jumlah Terjual* ($r = -0,16$), yang mengindikasikan bahwa kenaikan harga produk cenderung menurunkan jumlah penjualan. Variabel promosi lainnya, seperti *Potongan Harga*, *Voucher Penjual*, dan *Voucher Shopee*, memiliki nilai korelasi yang mendekati nol, sehingga hubungan linear langsung dengan jumlah terjual tidak signifikan. Secara keseluruhan, hasil ini menunjukkan tidak adanya multikolinearitas yang tinggi antar variabel independen. Selain itu, lemahnya hubungan linear antara fitur dan variabel target mengindikasikan bahwa pola permintaan bersifat kompleks dan non-linear, sehingga mendukung penggunaan metode *machine learning* non-linear seperti Support Vector Regression (SVR) dalam penelitian ini.

Pembuatan Model *Support Vector Regression* (SVR)

1. Pra-pemrosesan Data

Sebelum mengaplikasikan algoritma machine learning, dataset harus melalui serangkaian tahap pra-pemrosesan. Tujuan utama dari tahap ini adalah untuk memastikan kualitas, relevansi, dan formatabilitas data, sehingga data siap digunakan secara efektif dalam pelatihan model. Pra-pemrosesan yang komprehensif berkontribusi signifikan terhadap akurasi dan robustnya model yang dihasilkan.

- a. **Pembersihan Data:** Tahap awal pembersihan data diawali dengan deteksi nilai hilang (*missing values*) pada setiap fitur dalam dataset. Berdasarkan hasil pemeriksaan menyeluruh, tidak ditemukan adanya nilai hilang pada dataset yang digunakan. Oleh karena itu, tidak ada proses imputasi (pengisian nilai hilang) yang diperlukan pada tahap ini, sehingga nilai data asli tetap terjaga sebelum melangkah ke proses selanjutnya.
- b. **Rekayasa Fitur (Feature Engineering):** Mengingat algoritma *Support Vector Regression* (SVR) secara inheren beroperasi dengan data numerik, transformasi fitur (*feature engineering*) sangat penting untuk mengintegrasikan variabel kategorik. Kolom Kategori, Libur Nasional, dan Even Shopee diubah menjadi numerik menggunakan metode *One-Hot Encoding*. Metode ini menciptakan variabel biner baru untuk setiap kategori unik, sehingga model dapat memproses informasi kategorik tanpa mengasumsikan urutan atau skala.
- c. **Normalisasi Data:** Sensitivitas algoritma SVR terhadap skala fitur menuntut dilakukannya normalisasi data. *StandardScaler* digunakan untuk mentransformasi fitur-fitur numerik agar memiliki rata-rata nol dan standar deviasi satu. Normalisasi ini memastikan bahwa tidak ada fitur yang mendominasi perhitungan jarak karena rentang nilainya yang besar, sehingga setiap fitur berkontribusi secara proporsional dalam pelatihan model. Seluruh proses pra-pemrosesan ini, meliputi penskalaan dan *encoding* diintegrasikan ke dalam sebuah *pipeline preprocessing* untuk menjaga konsistensi, efisiensi, dan mencegah *data leakage* antara tahap pra-pemrosesan dan pemodelan.

2. Pembagian Data (Training dan Testing)

Setelah tahap pra-pemrosesan data, dataset dibagi menjadi dua subset yaitu data pelatihan (*training set*) dan data pengujian (*testing set*). Pembagian ini dilakukan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Sebesar 80% dari total data dialokasikan untuk pelatihan model, sedangkan 20% sisanya digunakan untuk pengujian. Pembagian dilakukan secara acak menggunakan fungsi `train_test_split` dari Scikit-learn, dengan `random_state` diatur ke nilai 42. Penetapan `random_state` memastikan reproduktibilitas hasil pembagian data, sehingga setiap kali eksperimen dijalankan, pembagian data akan tetap konsisten.

3. Pelatihan Model *Support Vector Regression* (SVR)

Model yang dipilih untuk prediksi dalam penelitian ini adalah *Support Vector Regression* (SVR), sebuah metode yang efektif untuk masalah regresi dengan fleksibilitas dalam menangani hubungan non-linear melalui penggunaan fungsi kernel. Proses pelatihan model diimplementasikan menggunakan *Pipeline* Scikit-learn, yang secara sistematis mengalirkan data melalui tahap pra-pemrosesan (penskalaan dan *encoding*) sebelum masuk ke tahap pemodelan SVR. Pendekatan *pipeline* ini menyederhanakan alur kerja dan meminimalkan potensi kesalahan.

Untuk mengidentifikasi kombinasi *hyperparameter* optimal bagi model SVR, teknik *Grid Search* dikombinasikan dengan validasi silang 5-fold ($cv=5$) diaplikasikan. *Grid Search* secara sistematis mengeksplorasi semua kombinasi *hyperparameter* yang telah ditentukan, sementara validasi silang memastikan evaluasi model yang robust dan mengurangi risiko *overfitting* terhadap satu partisi data tertentu. Berdasarkan hasil *Grid Search*, diperoleh kombinasi *hyperparameter* terbaik, dimana kernel yang digunakan adalah **RBF**, dengan nilai **C** paling optimal adalah 10, nilai **epsilon** optimal adalah 0.1, dan menggunakan **gamma** 'scale'. Kombinasi parameter inilah yang kemudian digunakan untuk melatih model SVR final.

4. Evaluasi Akurasi Model

Evaluasi performa model merupakan langkah krusial untuk menilai seberapa baik model SVR yang telah dilatih mampu memprediksi Jumlah Terjual. Evaluasi dilakukan dengan menggunakan empat metrik regresi standar, yaitu MAE, RMSE dan R^2 . Hasil evaluasi metrik pada data pengujian ditunjukkan pada Tabel berikut.

Tabel 4 Hasil Evaluasi Kinerja


Metrik Evaluasi	Pembagian Data 70:30	Pembagian Data 80:20
MAE	1,32	1,34
RMSE	3,68	3,73
R2	0,51	0,52

Berdasarkan Tabel 4 hasil evaluasi kinerja model menunjukkan bahwa model pada percobaan menggunakan pembagian 80% training dan 20% testing menghasilkan hasil lebih baik dimana memiliki MAE sebesar 1.32, menunjukkan rata-rata kesalahan absolut prediksi sebesar 1.34 unit. RMSE tercatat 3.73, merepresentasikan standar deviasi dari residu prediksi dan memberikan estimasi error dalam unit yang sama dengan variabel target. Terakhir, nilai R^2 sebesar 0.52 menunjukkan bahwa model mampu menjelaskan sekitar 52% variabilitas dalam variabel dependen. Meskipun nilai R^2 mengindikasikan kemampuan model untuk menjelaskan sebagian variansi data, masih ada 48% variansi yang belum dapat dijelaskan,

menunjukkan adanya ruang untuk peningkatan kinerja model melalui optimasi lebih lanjut atau penambahan fitur yang lebih relevan. Terdapat beberapa faktor mendasar yang menyebabkan performa model belum mencapai titik optimal:

- Dimensi Data yang Tinggi (High Dimensionality): Penerapan One-Hot Encoding pada variabel SKU menciptakan dimensi fitur yang sangat luas. Hal ini berpotensi menyebabkan fenomena sparsity (kerenggangan data), di mana algoritma SVR kesulitan menentukan hyperplane yang paling presisi di tengah banyaknya fitur biner yang dihasilkan.
- Variansi Penjualan yang Ekstrem: Selisih yang cukup lebar antara nilai MAE dan RMSE menunjukkan adanya outlier atau lonjakan penjualan pada periode tertentu yang tidak mampu diprediksi secara akurat oleh model. SVR cenderung melakukan generalisasi dengan meminimalkan kesalahan rata-rata, sehingga nilai-nilai ekstrim (produk yang sangat laris secara tiba-tiba) sering kali dianggap sebagai residu yang besar.
- Karakteristik Data Retail: Penjualan di platform e-commerce seperti Shopee sangat dipengaruhi oleh faktor eksternal yang tidak terekam sepenuhnya dalam dataset, seperti tren produk yang sedang viral, aktivitas iklan kompetitor, atau ketersediaan stok. Ketiadaan variabel tersebut menyebabkan model belum mampu menjelaskan sisa variansi sebesar 48% dari total data penjualan.

Secara teoritis, penggunaan kernel RBF pada SVR seharusnya mampu menangani pola non-linear. Namun, dalam kasus ini, kompleksitas data retail memerlukan pendekatan fitur yang lebih mendalam, seperti transformasi pada variabel target atau penggunaan metode pengkodean kategorikal yang lebih efisien untuk meningkatkan daya prediksi model.




Gambar 7 Perbandingan Nilai Prediksi vs Aktual

Gambar 7 menyajikan perbandingan nilai aktual dan prediksi untuk variabel Jumlah Terjual dalam bentuk *line plot*, menunjukkan bahwa model cenderung mengikuti tren umum data aktual, namun dengan kapasitas yang terbatas dalam menangkap nilai-nilai ekstrim. Secara visual, garis prediksi (oranye) terlihat lebih halus dan memiliki amplitudo yang lebih kecil dibandingkan garis nilai aktual (biru), terutama pada puncak-puncak yang tinggi. Hal ini mengindikasikan bahwa model memiliki kesulitan dalam mereplikasi variabilitas penuh dari data aktual. Meskipun demikian, model mampu menangkap pola dasar dan fluktuasi nilai yang lebih rendah. Keterbatasan ini dalam memprediksi nilai ekstrim dan variansi penuh sejalan dengan hasil evaluasi metrik sebelumnya, yang mungkin menunjukkan perlunya penyesuaian model lebih lanjut atau eksplorasi fitur tambahan untuk meningkatkan akurasi prediksi pada seluruh rentang data.

Implementasi Model Prediksi dan Implikasi Manajerial

Implementasi model prediksi diwujudkan melalui pengembangan dan implementasi dashboard prediksi permintaan yang dibangun dengan memanfaatkan model peramalan yang telah dihasilkan. Model kemudian di deploy ke dalam sebuah aplikasi berbasis web dengan menggunakan platform Streamlit. Dashboard ini dirancang untuk menyajikan informasi prediksi secara interaktif, mudah diakses, serta memungkinkan pengguna melakukan simulasi berbagai skenario harga, promosi, maupun variabel operasional lainnya.



The screenshot shows a web application titled "Prediksi Jumlah Permintaan Produk" (Product Demand Prediction). The interface includes the following input fields:

- SKU: A text input field.
- Kategori: A dropdown menu.
- Harga Awal: A numeric input field with a "0" placeholder and minus/plus buttons.
- Potongan Harga: A numeric input field with a "0" placeholder and minus/plus buttons.
- Voucher Perjual: A numeric input field with a "0" placeholder and minus/plus buttons.
- Voucher Shopee: A numeric input field with a "0" placeholder and minus/plus buttons.
- Potongan Koin Shopee: A numeric input field with a "0" placeholder and minus/plus buttons.
- Diskon Ongkos Kirim: A numeric input field with a "0" placeholder and minus/plus buttons.
- Libur Nasional: A dropdown menu.
- Even Shopee: A dropdown menu.

At the bottom of the form is a button labeled "Prediksi".

Gambar 8 Dashboard Prediksi Permintaan

Melalui dashboard prediksi permintaan tersebut, diharapkan dapat memberikan beberapa manfaat dan rekomendasi manajerial sebagai berikut:

1. **Implikasi Terhadap Manajemen Inventori:** Dengan tingkat akurasi model yang mampu menangkap pola permintaan umum, merchant dapat memanfaatkan hasil prediksi sebagai dasar perencanaan persediaan yang lebih presisi. Prediksi permintaan memungkinkan merchant mengantisipasi fluktuasi penjualan, terutama pada periode promosi dan event tertentu, sehingga dapat menyesuaikan tingkat stok secara optimal. Pendekatan ini berpotensi mengurangi risiko overstock pada periode permintaan rendah serta meminimalkan kejadian stockout pada saat terjadi lonjakan permintaan.
2. **Implikasi Terhadap Strategi Pemasaran dan Promosi:** Melalui dashboard prediksi yang dikembangkan, merchant dapat melakukan simulasi berbagai skenario promosi misalnya perubahan harga atau kombinasi voucher untuk melihat dampaknya terhadap permintaan

sebelum strategi tersebut diterapkan. Hal ini memungkinkan perancangan strategi pemasaran yang lebih terukur sesuai karakteristik produk dan periode penjualan.

3. **Implikasi terhadap Profitabilitas Bisnis:** Dengan prediksi yang relatif akurat, merchant dapat menekan biaya operasional yang tidak efisien, seperti biaya penyimpanan akibat kelebihan stok maupun kehilangan potensi pendapatan akibat kekurangan stok. Di sisi lain, strategi promosi yang lebih tepat sasaran berdasarkan variabel yang terbukti berpengaruh terhadap penjualan dapat mengurangi pemborosan anggaran promosi yang tidak efektif. Dengan demikian, hasil penelitian ini menunjukkan bahwa penerapan model prediksi permintaan tidak hanya berfungsi sebagai alat analitis, tetapi juga sebagai instrumen strategis untuk mendukung keberlanjutan dan profitabilitas bisnis merchant secara jangka menengah hingga panjang.

KESIMPULAN

Hasil evaluasi menunjukkan bahwa model SVR dengan kernel RBF mampu menjelaskan sekitar setengah variabilitas data permintaan dengan tingkat kesalahan yang relatif moderat, serta mampu menangkap pola umum dan tren permintaan meskipun masih memiliki keterbatasan dalam memprediksi nilai ekstrim. Dengan demikian, model ini dapat digunakan sebagai alat prediktif yang cukup andal untuk mengantisipasi kecenderungan lonjakan maupun penurunan permintaan produk berdasarkan kombinasi faktor harga, promosi, event, dan karakteristik waktu.

Selanjutnya, hasil prediksi permintaan yang dihasilkan dapat dimanfaatkan oleh pihak merchant dalam mendukung pengambilan keputusan bisnis yang lebih efektif dan efisien. Prediksi yang dihasilkan membantu merchant dalam merancang strategi pemasaran yang lebih tepat sasaran, misalnya dengan memaksimalkan jenis promosi yang terbukti berpengaruh signifikan terhadap penjualan seperti diskon ongkos kirim dan insentif dari platform. Selain itu, prediksi permintaan dapat digunakan sebagai dasar dalam pengelolaan inventori, sehingga merchant dapat menyesuaikan tingkat stok untuk menghindari kelebihan persediaan maupun resiko kehabisan barang. Implementasi model dalam bentuk dashboard interaktif juga memberikan nilai tambah praktis, karena memungkinkan merchant melakukan simulasi berbagai skenario harga dan promosi sebelum diterapkan secara nyata.

DAFTAR PUSTAKA

- Ahmadov, Y., & Helo, P. (2023). Deep learning-based approach for forecasting intermittent online sales. *Discover Artificial Intelligence*, 3(1), 45. <https://doi.org/10.1007/s44163-023-00071-1>
- Cameron, A. C., & Windmeijer, F. A. (1997). An R-squared measure of goodness of fit for some common nonlinear regression models. *Journal of Econometrics*, 77(2), 329–342. [https://doi.org/10.1016/S0304-4076\(96\)01818-0](https://doi.org/10.1016/S0304-4076(96)01818-0)
- Chowdhury, A. R., Paul, R., & Rozony, F. Z. (2025). A systematic review of demand forecasting models for retail e-commerce enhancing accuracy in inventory and delivery planning. *International Journal of Scientific Interdisciplinary Research*, 6(1), 1–27.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273–297. <https://doi.org/10.1007/BF00994018>
- de Lange, A. M. G., Anatürk, M., Suri, S., Kaufmann, T., Cole, J. H., Griffanti, L., Zsoldos, E., Filippini, N., Singh-Manoux, A., Kivimäki, M., & Ebmeier, K. P. (2022). Mind the

- gap: Performance metric evaluation in brain-age prediction. *Human Brain Mapping*, 43(10), 3113–3129. <https://doi.org/10.1002/hbm.25837>
- Faber, N. K. M. (1999). Estimating the uncertainty in estimates of root mean square error of prediction: Application to determining the size of an adequate test set in multivariate calibration. *Chemometrics and Intelligent Laboratory Systems*, 49(1), 79–89. [https://doi.org/10.1016/S0169-7439\(99\)00027-1](https://doi.org/10.1016/S0169-7439(99)00027-1)
- Fan, W., Zheng, W., Yan, H., & Fan, S. (2023). Support vector regression model for flight demand forecasting. *International Journal of Engineering Business Management*, 15, 18479790231174320. <https://doi.org/10.1177/18479790231174318>
- Febriani, K., & Fatichah, C. (2024). Coal demand prediction model using machine learning methods. *JUTI: Jurnal Ilmiah Teknologi Informasi*, 65–77. <https://doi.org/10.12962/j24068535.v22i1.a1576>
- Febrianti, W., & Hasan, R. (2022). Impact of product quality and brand image towards buying decisions with buying interest as mediation variable. *Journal Research of Social, Science, Economics, and Management*, 1(11), 1899–1912. <https://doi.org/10.36418/jrssem.v1i11.213>
- Gahlot, B., & Rani, P. (2023). A study of digital marketing strategies influencing buying behaviour of e-commerce consumers. *RESEARCH REVIEW International Journal of Multidisciplinary*, 8(6), 99–103. <https://doi.org/10.31305/rrijm.2023.v08.n06.013>
- Gopagoni, D. R., Lakshmi, P. V., & Chaudhary, A. (2020). Evaluating machine learning algorithms for marketing data analysis: Predicting grocery store sales. In *Communication Software and Networks: Proceedings of INDIA 2019* (pp. 155–163). Springer. https://doi.org/10.1007/978-981-15-5397-4_17
- Guo, L., Cheng, Z., Tian, J., & Chen, B. (2021). The hybrid PROPHET-SVR approach for forecasting product time series demand with seasonality. *Computers & Industrial Engineering*, 161, 107598. <https://doi.org/10.1016/j.cie.2021.107598>
- Güven, İ., & Şimşir, F. (2020). Demand forecasting with color parameter in retail apparel industry using artificial neural networks (ANN) and support vector machines (SVM) methods. *Computers & Industrial Engineering*, 147, 106678. <https://doi.org/10.1016/j.cie.2020.106678>
- Hedianti, E. S. (2019). *Peramalan harga saham dengan menggunakan metode support vector regression (SVR)*. Institut Teknologi Sepuluh Nopember.
- Holst, E., & Thyregod, P. (1999). A statistical test for the mean squared error. *Journal of Statistical Computation and Simulation*, 63(4), 321–347. <https://doi.org/10.1080/00949659908811962>
- Kilimci, Z. H., Akyuz, A. O., Uysal, M., Akyokus, S., Uysal, M. O., Atak Bulbul, B., & Ekmis, M. A. (2019). An improved demand forecasting model using deep learning approach and proposed decision integration strategy for supply chain. *Complexity*, 2019(1), 9067367. <https://doi.org/10.1155/2019/9067367>
- Lestari, L. D., & Dwijayanti, R. (2022). Pengaruh fenomena harbolnas (hari belanja online nasional) pada e-commerce Shopee melalui diskon dan kemudahan bertransaksi terhadap keputusan pembelian. *Jurnal Pendidikan Tata Niaga (JPTN)*, 10(1), 1482–1491. <https://doi.org/10.26740/jptn.v10n1.p1482-1491>
- Li, Z., & Zhang, N. (2022). Short-term demand forecast of e-commerce platform based on ConvLSTM network. *Computational Intelligence and Neuroscience*, 2022(1), 5227829. <https://doi.org/10.1155/2022/5227829>
- Liu, H., Wang, X., Chen, Y., & Zhao, Y. (2023). Hybrid prediction model for cold load in large public buildings based on mean residual feedback and improved SVR. *Energy and Buildings*, 294, 113229. <https://doi.org/10.1016/j.enbuild.2023.113229>
- Ma, J., Zhou, S., & Li, D. (2021). Robust multiclass least squares support vector classifier with

- optimal error distribution. *Knowledge-Based Systems*, 215, 106652. <https://doi.org/10.1016/j.knosys.2021.106652>
- Palgunadi, T. L., Prasetya, D. A., Ningsih, R., & Widyastuti, R. (2024). Optimizing demand forecasting method with support vector regression for improved inventory planning. *Jurnal Optimasi Sistem Industri*, 23(2), 149–166. <https://doi.org/10.25077/josi.v23.n2.p149-166.2024>
- Prayitno, S. B. (2023). Analysis of the perception of free shipping promotions on purchasing decisions on the Shopee marketplace. *Journal of Management Science (JMAS)*, 6(2), 199–205. <https://doi.org/10.35335/jmas.v6i2.127>
- Punia, S., & Shankar, S. (2022). Predictive analytics for demand forecasting: A deep learning-based decision support system. *Knowledge-Based Systems*, 258, 109956. <https://doi.org/10.1016/j.knosys.2022.109956>
- Qi, J., Du, J., Siniscalchi, S. M., Ma, X., & Lee, C. H. (2020). On mean absolute error for deep neural network based vector-to-vector regression. *IEEE Signal Processing Letters*, 27, 1485–1489. <https://doi.org/10.1109/LSP.2020.3016837>
- Raju, S. T. U., Pakala, R., Reddy, G. H., & Manivannan, D. (2022). An approach for demand forecasting in steel industries using ensemble learning. *Complexity*, 2022(1), 9928836. <https://doi.org/10.1155/2022/9928836>
- Robeson, S. M., & Willmott, C. J. (2023). Decomposition of the mean absolute error (MAE) into systematic and unsystematic components. *PloS One*, 18(2), e0279774. <https://doi.org/10.1371/journal.pone.0279774>
- Sheehan, D., Hardesty, D. M., Szakaly, F. G., & Kim, H. (2019). Consumer reactions to price discounts across online shopping experiences. *Journal of Retailing and Consumer Services*, 51, 129–138. <https://doi.org/10.1016/j.jretconser.2019.06.006>
- Statista. (2024). *Baby Diapers - Indonesia*. Statista. <https://www.statista.com/outlook/cmo/tissue-hygiene-paper/baby-diapers/indonesia>
- Svetunkov, I., Kourentzes, N., & Ord, J. K. (2022). Complex exponential smoothing. *Naval Research Logistics (NRL)*, 69(8), 1108–1123. <https://doi.org/10.1002/nav.22074>
- Tello, M., Besari, A. R. A., Rahmatullah, B., & Wahyunggoro, O. (2022). Machine learning based forecast for the prediction of inpatient bed demand. *BMC Medical Informatics and Decision Making*, 22(1), 55. <https://doi.org/10.1186/s12911-022-01787-9>
- Vinny, V., Pangaribuan, J. J., & Romindo, R. (2023). Pengembangan sistem persediaan berbasis web pada UMKM. *Journal Information System Development (ISD)*, 8(2), 79–86. <https://doi.org/10.24114/isd.v8i2.44622>
- Wang, C., & Wang, J. (2025). Research on e-commerce inventory sales forecasting model based on ARIMA and LSTM algorithm. *Mathematics*, 13(11), 1838. <https://doi.org/10.3390/math13111838>
- Wang, Y., & Zhang, Y. (2023). Multivariate SVR demand forecasting for beauty products based on online reviews. *Mathematics*, 11(21), 4420. <https://doi.org/10.3390/math11214420>
- Were, K., Bui, D. T., Dick, Ø. B., & Singh, B. R. (2015). A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping soil organic carbon stocks across an Afromontane landscape. *Ecological Indicators*, 52, 394–403. <https://doi.org/10.1016/j.ecolind.2014.12.028>
- Zafira, F., Irawan, B., & Bahtiar, A. (2024). Penerapan data mining untuk estimasi stok barang dengan metode K-means clustering. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(1), 156–161. <https://doi.org/10.36040/jati.v8i1.7748>
- Zhang, F., & O'Donnell, L. J. (2020). Support vector regression. In *Machine Learning* (1st ed., pp. 123–140). Academic Press. <https://doi.org/10.1016/B978-0-12-815739-8.00007-9>