

# Implementasi Linear Regression untuk Prediksi Pemesanan Atribut Sekolah

## *Implementation of Linear Regression for Predicting School Attribute Orders*

<sup>1</sup>Dhani Miftahul Abid\*, <sup>2</sup>Arif Setiawan, <sup>3</sup>Muhammad Arifin

<sup>1,2,3</sup>Program Studi Sistem Informasi, Fakultas Teknik, Universitas Muria Kudus

<sup>1,2,3</sup>Jl. Lingkar Utara UMK, Desa Gondangmanis, Kecamatan Bae, Kabupaten Kudus, Jawa Tengah Indonesia

\*e-mail: [202153049@std.umk.ac.id](mailto:202153049@std.umk.ac.id)

(received: 14 June 2026, revised: 15 June 2026, accepted: 20 June 2026)

### Abstrak

Fluktuasi permintaan atribut sekolah seperti topi dan dasi menjadi tantangan bagi industri konveksi dalam menentukan jumlah produksi yang tepat. Ketidakakuratan perencanaan produksi dapat menyebabkan kelebihan persediaan maupun kekurangan stok yang berdampak pada biaya operasional dan pelayanan pelanggan. Penelitian ini bertujuan untuk mengimplementasikan metode Linear Regression dalam memprediksi jumlah pemesanan atribut sekolah berdasarkan data historis periode 2021–2025. Penelitian menggunakan pendekatan kuantitatif dengan tahapan preprocessing data, feature engineering, pembagian data menggunakan skema training 80% dan testing 20%, serta pembangunan model prediksi menggunakan Linear Regression. Variabel yang digunakan meliputi tahun, bulan, tingkat pendidikan, jenis produk, time index, semester, dan tahun ajaran baru. Hasil penelitian menunjukkan bahwa model mampu menghasilkan nilai Mean Absolute Percentage Error (MAPE) sebesar 12,91% dan Mean Absolute Error (MAE) sebesar 149,61 unit. Hasil tersebut menunjukkan bahwa metode Linear Regression memiliki tingkat akurasi yang baik dalam memprediksi jumlah pemesanan atribut sekolah. Selain itu, faktor semester, jenis produk, dan periode tahun ajaran baru diketahui memiliki pengaruh terhadap perubahan permintaan. Model yang dihasilkan dapat dimanfaatkan sebagai pendukung pengambilan keputusan dalam perencanaan produksi dan pengelolaan persediaan pada industri konveksi.

**Kata kunci:** linear regression, prediksi pemesanan, atribut sekolah, forecasting permintaan, perencanaan produksi

### Abstract

*Fluctuating demand for school accessories, such as caps and neckties, presents a significant challenge for the garment manufacturing industry in determining optimal production quantities. Inaccurate production planning can lead to overstocking or stock shortages, resulting in increased operational costs and reduced customer service quality. This study aims to implement a Linear Regression model to predict school accessory orders using historical sales data from 2021 to 2025. A quantitative research approach was adopted, consisting of data preprocessing, feature engineering, dataset partitioning into 80% training and 20% testing sets, and the development of a prediction model using Linear Regression. The input variables included year, month, education level, product type, time index, semester, and new academic year period. The experimental results demonstrate that the proposed model achieved a Mean Absolute Percentage Error (MAPE) of 12.91% and a Mean Absolute Error (MAE) of 149.61 units, indicating good predictive performance for forecasting school accessory orders. Furthermore, semester, product type, and the new academic year period were identified as key factors influencing demand fluctuations. The proposed model can serve as a decision-support tool for production planning and inventory management in the garment manufacturing industry, enabling more efficient resource allocation and demand-driven production planning.*


**Keywords:** linear regression, order prediction, school attributes, demand forecasting, production planning

<http://sistemasi.ftik.unisi.ac.id>

## 1 Pendahuluan

Perkembangan teknologi informasi telah mendorong pemanfaatan data sebagai dasar pengambilan keputusan pada berbagai sektor bisnis, termasuk industri konveksi [1]. Salah satu penerapan yang banyak digunakan adalah forecasting atau peramalan, yaitu proses memperkirakan kebutuhan di masa mendatang berdasarkan data historis [2]. Kemampuan melakukan peramalan secara akurat menjadi faktor penting bagi perusahaan dalam menyusun perencanaan produksi, mengelola persediaan, serta meminimalkan risiko kerugian akibat ketidaksesuaian antara jumlah produksi dan permintaan pasar [3].

Industri konveksi yang memproduksi atribut sekolah seperti topi, dasi, dan perlengkapan sekolah lainnya memiliki karakteristik permintaan yang cenderung berubah dari waktu ke waktu. Perubahan tersebut dipengaruhi oleh berbagai faktor, seperti periode penerimaan peserta didik baru, pergantian tahun ajaran, serta kebutuhan institusi pendidikan terhadap atribut sekolah. Berdasarkan data historis pemesanan yang dimiliki perusahaan, terlihat adanya fluktuasi jumlah pesanan pada setiap periode pengamatan sebagaimana ditunjukkan pada gambar dibawah ini, Kondisi tersebut menunjukkan bahwa pola permintaan tidak selalu stabil sehingga diperlukan pendekatan yang mampu memperkirakan jumlah pesanan secara lebih objektif dan terukur.



**Gambar 1 Data permintaan barang tahun 2021-2025**

Berdasarkan data historis pemesanan yang dimiliki konveksi, terlihat adanya fluktuasi jumlah pesanan pada setiap periode pengamatan sebagaimana ditunjukkan pada Gambar 1. Kondisi tersebut menunjukkan bahwa pola permintaan tidak selalu stabil sehingga diperlukan pendekatan yang mampu memperkirakan jumlah pesanan secara lebih objektif dan terukur. Fluktuasi permintaan yang terjadi menjadi tantangan bagi perusahaan dalam menentukan jumlah produksi yang tepat. Produksi yang melebihi kebutuhan dapat menyebabkan penumpukan stok dan meningkatnya biaya penyimpanan [4], sedangkan produksi yang lebih rendah dari permintaan berpotensi mengakibatkan keterlambatan pemenuhan pesanan dan hilangnya peluang penjualan [5]. Oleh karena itu, perusahaan membutuhkan metode yang dapat membantu memprediksi jumlah pesanan pada periode mendatang sehingga proses perencanaan produksi dapat dilakukan dengan lebih efektif.

Pada praktiknya, perencanaan produksi pada banyak usaha konveksi masih dilakukan berdasarkan pengalaman dan perkiraan subjektif pemilik usaha. Pendekatan tersebut sering kali belum mampu memanfaatkan data historis secara optimal sebagai sumber informasi pengambilan keputusan [6]. Padahal, data pemesanan yang tersimpan selama beberapa tahun dapat digunakan untuk mengidentifikasi pola permintaan dan menghasilkan prediksi yang lebih akurat. Pemanfaatan data historis melalui metode analisis yang tepat diharapkan mampu meningkatkan kualitas keputusan yang diambil oleh perusahaan.

Salah satu metode yang dapat digunakan untuk melakukan prediksi adalah Linear Regression. Metode ini digunakan untuk memodelkan hubungan antara variabel independen dan variabel dependen sehingga dapat digunakan untuk memperkirakan nilai pada periode berikutnya. Linear Regression memiliki keunggulan berupa proses implementasi yang sederhana, mudah dipahami, serta mampu menggambarkan kecenderungan tren berdasarkan data historis [7]. Dengan karakteristik

tersebut, metode ini dinilai sesuai untuk diterapkan pada data pemesanan atribut sekolah yang tersusun berdasarkan periode waktu.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengimplementasikan metode Linear Regression dalam memprediksi jumlah pemesanan atribut sekolah berdasarkan data historis pemesanan. Hasil penelitian diharapkan dapat membantu perusahaan dalam menyusun perencanaan produksi yang lebih akurat, mengurangi risiko kelebihan maupun kekurangan stok, serta mendukung pengambilan keputusan yang lebih efektif dan berbasis data.

## 2 Tinjauan Literatur

Peramalan permintaan telah menjadi salah satu topik yang banyak diteliti karena berperan penting dalam mendukung pengambilan keputusan operasional dan strategis pada berbagai sektor industri. Berbagai pendekatan telah dikembangkan untuk meningkatkan akurasi prediksi, mulai dari metode statistik konvensional hingga algoritma machine learning. Pemilihan metode yang tepat menjadi faktor penting karena karakteristik data yang berbeda akan menghasilkan performa model yang berbeda pula.

Penelitian yang dilakukan oleh [8] menunjukkan bahwa algoritma XGBoost mampu menghasilkan nilai MAPE sebesar 10,2% dalam memprediksi penjualan fast food. Hasil tersebut menunjukkan bahwa pendekatan machine learning memiliki kemampuan yang baik dalam menangkap pola historis data. Namun demikian, model XGBoost memerlukan proses tuning parameter yang cukup kompleks sehingga implementasinya menjadi lebih sulit, terutama pada lingkungan usaha kecil dan menengah yang memiliki keterbatasan sumber daya teknis. Temuan tersebut menunjukkan bahwa tingginya akurasi tidak selalu diikuti oleh kemudahan implementasi.

Di sisi lain, pendekatan statistik masih banyak digunakan karena memiliki mekanisme yang lebih sederhana. [9] menerapkan Triple Exponential Smoothing untuk memprediksi tonase penjualan dan memperoleh nilai MAPE sebesar 11,55%. Hasil tersebut menunjukkan bahwa metode ini cukup efektif dalam menangani pola tren dan musiman. Penelitian serupa dilakukan oleh Putro dkk. (2021) menggunakan Double Exponential Smoothing pada prediksi penjualan kertas dengan tingkat akurasi mencapai 82%–88%. Kedua penelitian tersebut menunjukkan bahwa metode statistik masih relevan digunakan pada data yang memiliki pola tertentu, meskipun kemampuannya dalam menangkap hubungan yang lebih kompleks masih terbatas.

Perkembangan metode time series modern juga memberikan alternatif lain dalam peramalan permintaan. Penelitian [10] membandingkan metode Prophet dan ARIMA dalam forecasting produksi gas. Hasil penelitian menunjukkan bahwa Prophet memiliki performa yang lebih baik dibandingkan ARIMA dengan nilai MAPE sebesar 20,32%. Temuan ini mengindikasikan bahwa model yang mampu mengakomodasi tren dan perubahan pola data cenderung memberikan hasil yang lebih baik dibandingkan model time series konvensional. Namun demikian, tingkat kesalahan yang masih relatif tinggi menunjukkan bahwa masih terdapat ruang untuk meningkatkan kualitas prediksi.

Kemampuan menangkap pola musiman juga menjadi fokus dalam berbagai penelitian forecasting. [11] menerapkan metode SARIMA untuk meramalkan penjualan pada usaha bakery dan memperoleh nilai MAPE sebesar 15,42%. Hasil tersebut menunjukkan bahwa model mampu mengidentifikasi pola musiman yang terdapat pada data penjualan. Meskipun demikian, penurunan performa pada data pengujian mengindikasikan adanya keterbatasan model dalam melakukan generalisasi terhadap data baru yang belum pernah diamati sebelumnya.

Selain metode statistik dan time series, pendekatan machine learning berbasis Support Vector Machine (SVM) juga telah digunakan untuk memprediksi penjualan. Penelitian yang dilakukan oleh [12] menghasilkan nilai MAPE sebesar 21,44% pada prediksi penjualan lampu. Walaupun metode ini memiliki kemampuan dalam menangani hubungan nonlinier antarvariabel, performanya sangat dipengaruhi oleh proses normalisasi data dan penentuan parameter model. Kondisi tersebut menunjukkan bahwa kompleksitas model sering kali menjadi tantangan tersendiri dalam implementasi forecasting pada lingkungan bisnis nyata.

Berdasarkan berbagai penelitian tersebut, dapat disimpulkan bahwa sebagian besar studi terdahulu berfokus pada peningkatan akurasi model melalui penggunaan metode yang semakin kompleks. Namun, penelitian terkait prediksi pemesanan atribut sekolah pada industri konveksi masih relatif terbatas. Selain itu, belum banyak penelitian yang mengkaji penggunaan metode yang

sederhana, mudah diinterpretasikan, dan mudah diterapkan sebagai dasar perencanaan produksi pada usaha konveksi. Padahal, kemudahan implementasi dan interpretasi model merupakan aspek penting agar hasil prediksi dapat dimanfaatkan secara langsung oleh pelaku usaha dalam proses pengambilan keputusan.

Oleh karena itu, penelitian ini berfokus pada implementasi metode Linear Regression untuk memprediksi jumlah pemesanan atribut sekolah berdasarkan data historis pemesanan. Berbeda dengan penelitian sebelumnya yang banyak menggunakan metode forecasting dengan kompleksitas tinggi, penelitian ini menekankan pada pemanfaatan model yang lebih sederhana dan mudah diimplementasikan tanpa mengabaikan kemampuan prediktifnya. Hasil penelitian diharapkan dapat memberikan informasi yang berguna dalam mendukung perencanaan produksi serta menjadi referensi penerapan metode forecasting pada industri konveksi.

### 3 Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan memanfaatkan data historis pemesanan atribut sekolah pada salah satu usaha konveksi selama periode 2021–2025. Dataset yang digunakan terdiri dari informasi kategori produk, bulan pemesanan, tahun pemesanan, dan jumlah pesanan. Data diperoleh melalui dokumentasi arsip transaksi perusahaan yang kemudian digunakan sebagai dasar dalam proses pembangunan model prediksi. Data historis tersebut dipilih karena mampu menggambarkan pola permintaan yang terjadi dari waktu ke waktu sehingga dapat dimanfaatkan untuk membangun model prediksi yang mendukung perencanaan produksi pada periode mendatang.

Tabel 1 Dataset tahun 2021

Bulan	SD TOPI	SD DASI	SMP TOPI	SMP DASI	SMA TOPI	SMA DASI	SMK TOPI	SMK DASI
Januari	1382	915	1229	948	896	871	1106	938
Februari	1420	849	1137	688	853	739	864	670
Maret	1256	957	1220	613	905	845	914	657
April	896	780	864	653	821	587	608	569
Mei	818	551	684	564	610	477	578	518
Juni	650	636	560	352	637	506	585	585
Juli	2292	1540	1884	1291	1603	1162	1712	1286
Agustus	2311	1401	2073	1463	1721	1389	1788	1301
September	1883	1292	1520	934	1381	1046	1330	1003
Oktober	1237	935	1084	805	1069	801	1012	845
November	1249	748	970	680	1070	737	1138	922
Desember	1301	758	1116	649	1014	590	1110	728

#### 3.1 Preprocessing

Tahap pra-pemrosesan dilakukan untuk meningkatkan kualitas data sebelum digunakan dalam proses pemodelan. Proses ini meliputi pembersihan data (data cleaning), penghapusan data yang tidak lengkap, standarisasi format penulisan kategori dan bulan, serta transformasi data ke dalam bentuk numerik. Nama bulan dikonversi menjadi nilai numerik 1–12, sedangkan kategori produk diubah menjadi representasi numerik menggunakan teknik encoding sehingga dapat diproses oleh algoritma Linear Regression.

#### 3.2 Feature Engineering

Untuk meningkatkan kemampuan model dalam mengenali pola permintaan, dilakukan pembentukan fitur tambahan (feature engineering). Fitur yang digunakan meliputi *Time Index* sebagai representasi urutan waktu, *Semester* untuk membedakan periode semester pertama dan kedua, serta *Tahun Ajaran Baru* yang digunakan untuk mengidentifikasi periode dengan potensi peningkatan permintaan atribut sekolah. Variabel yang digunakan dalam penelitian ini ditunjukkan pada Tabel 1.

### 3.3 Split Dataset

Dataset dibagi menjadi dua bagian, yaitu data pelatihan (*training data*) sebesar 80% dan data pengujian (*testing data*) sebesar 20%. Data pelatihan digunakan untuk membangun model prediksi, sedangkan data pengujian digunakan untuk mengevaluasi kemampuan model dalam memprediksi data yang belum pernah diamati sebelumnya. Pembagian data dilakukan berdasarkan urutan waktu untuk mempertahankan karakteristik data deret waktu (*time series*).

### 3.4 Linier Reggression

Metode yang digunakan dalam penelitian ini adalah Linear Regression. Metode ini digunakan untuk memodelkan hubungan antara variabel independen dan variabel dependen sehingga dapat menghasilkan nilai prediksi berdasarkan pola data historis [13]. Linear Regression dipilih karena memiliki implementasi yang sederhana, mudah diinterpretasikan, serta mampu menggambarkan kecenderungan tren pada data permintaan. Model dibangun menggunakan persamaan regresi linear sebagaimana ditunjukkan pada Persamaan (1).

$$Y = a + bX + e \quad (1)$$

Dengan,  $Y$  = jumlah pemesanan atribut sekolah,  $\beta_0$  = konstanta,  $\beta_1, \beta_2, \dots, \beta_n$  = koefisien regresi,  $X_1, X_2, \dots, X_n$  = variabel independen, dan  $\varepsilon$  = galat (*error*).

### 3.5 Evaluasi Model

**3.5.1 Mean Absolute Percentage Error (MAPE)** digunakan untuk mempresentasikan nilai kesalahan dalam bentuk persentase sebagaimana ditunjukkan dalam persamaan (2) sehingga lebih mudah diinterpretasikan oleh pihak manajemen dalam menilai akurasi peramalan [14]

$$1^n \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (2)$$

Dengan,  $A_t$  merupakan nilai aktual pada periode ke- $t$ ,  $F_t$  merupakan nilai hasil prediksi pada periode ke- $t$ , dan  $n$  merupakan jumlah data pengamatan yang digunakan dalam proses evaluasi.

**3.5.2 Mean Squared Error (MSE)** digunakan untuk mengukur rata-rata selisih kuadrat antara nilai aktual dan nilai prediksi. Penggunaan MSE sangat penting dalam peramalan ini karena memberikan penalti yang lebih besar terhadap selisih angka yang signifikan, sehingga peneliti dapat mendeteksi adanya anomali atau *error* besar pada bulan-bulan tertentu dengan lebih sensitif [15] sebagaimana ditunjukkan pada persamaan (3).

$$MSE = \sum \frac{(A_t - F_t)^2}{n} \quad (3)$$

Dengan,  $A_t$  merupakan nilai aktual pada periode ke- $t$ ,  $F_t$  merupakan nilai hasil prediksi pada periode ke- $t$ , dan  $n$  merupakan jumlah data pengamatan yang digunakan dalam proses evaluasi.

## 4 Hasil dan Pembahasan

Bagian ini menyajikan hasil dari setiap tahapan komputasi yang dilakukan, mulai dari pra-pemrosesan data hingga implementasi model *Linear Regression* untuk memprediksi permintaan atribut sekolah. Pembahasan difokuskan pada interpretasi logis dari pola data historis (2021–2025) serta performa model dalam melakukan proyeksi untuk periode 2026.

### 4.1 Hasil Preprocessing

Tahap *preprocessing* dilakukan dengan menghapus *missing values* melalui fungsi *dropna()* untuk mencegah bias estimasi parameter model. Pada tahap transformasi, variabel Bulan dikonversi menjadi numerik ordinal (1–12). Selanjutnya, fitur gabungan dipecah menggunakan metode *string splitting* menjadi dua variabel independen: Tingkat dan Produk. Kedua fitur kategorikal ini kemudian

dikonversi menggunakan *label encoding* berbasis alfabet, menghasilkan kode untuk Tingkat (SD=0, SMA=1, SMK=2, SMP=3) dan Produk (DASI=0, TOPI=1). Akhirnya, dataset diurutkan secara kronologis berdasarkan tahun dan bulan, dengan sampel variasi pola data yang disajikan pada Tabel 2.


**Tabel 2 Sampel struktur data hasil transformasi**

Tahun	Bulan	Kategori	Bulan	Tingkat	Produk
2021	Januari	SD Topi	1	0	1
2021	Februari	SD Dasi	2	0	0
2021	Maret	SMP Topi	3	3	1
2021	April	SMP Dasi	4	3	0
2021	Mei	SMA Topi	5	1	1

## 4.2 Analisis Hasil Featuring Engineering

Model *Linear Regression* secara alamiah memiliki keterbatasan (*rigidity*) dalam menangkap fluktuasi non-linear atau lonjakan ekstrem pada periode tertentu. Untuk mengatasi kelemahan tersebut, dilakukan proses *feature engineering* dengan mengintroduksi tiga variabel prediktor baru berbasis karakteristik bisnis, yaitu *Time\_Index*, *Semester*, dan *Tahun\_Ajaran\_Baru*.

Fitur *Time\_Index* difungsikan untuk menangkap tren pertumbuhan sekuler jangka panjang seiring berjalannya waktu. Sementara itu, fitur *Semester* dan variabel biner *Tahun\_Ajaran\_Baru* (bernilai 1 pada bulan Mei–Agustus) bertindak sebagai stimulus kontekstual yang menggeser nilai intersep regresi secara vertikal. Penambahan fitur-fitur ini terbukti secara signifikan mampu membimbing model linear dalam merekonstruksi pola musiman serta menangkap lompatan kuantum (*quantum leaps*) volume permintaan saat memasuki masa *peak season*.



**Gambar 2 Matriks kolerasi**

Matriks korelasi ditunjukkan pada gambar 2 bahwa variabel *Semester* (0.54) merupakan penggerak utama (*primary driver*) volume permintaan, disusul oleh pengaruh diferensiasi jenis Produk (0.39). Tren pertumbuhan bisnis jangka panjang (*long-term growth*) terkonfirmasi stabil melalui korelasi positif pada *Time\_Index* (0.24) dan *Tahun* (0.20). Meskipun korelasi linear

Tahun\_Ajaran\_Baru (0.18) cenderung rendah, fitur biner ini tetap krusial sebagai prediktor musiman (*seasonal shock*) untuk menangkap lompatan kuantum pesanan pada *peak season*. Sebaliknya, korelasi negatif pada Tingkat (-0.12) mengonfirmasi penurunan frekuensi penggantian atribut seiring meningkatnya jenjang pendidikan siswa.

### 4.3 Split Dataset

Dataset historis (2021–2025) dibagi secara kronologis dengan proporsi 80% untuk data pelatihan (384 baris) dan 20% untuk data pengujian (96 baris). Pemisahan berbasis waktu (*time-series split*) ini diterapkan untuk menghindari bias. Data pelatihan digunakan untuk mengestimasi parameter model, sedangkan data pengujian berfungsi sebagai instrumen validasi independen untuk mengukur performa prediksi model terhadap tren masa depan.

### 4.4 Evaluasi Performa Model

Guna mengukur tingkat akurasi dan keandalan model *Linear Regression* yang telah dilatih, dilakukan pengujian menggunakan data *testing* (96 baris) melalui dua metrik evaluasi utama, yaitu *Mean Absolute Percentage Error* (MAPE) dan *Mean Absolute Error* (MAE).

#### 4.4.1 MAPE


Berdasarkan hasil pengujian pada data deviasi relatif, model menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 12,91%. Dalam standardisasi evaluasi peramalan, nilai MAPE yang berada di rentang 10% hingga 20% mengklasifikasikan performa model ke dalam kategori baik (*good forecasting*). Nilai 12,91% ini merepresentasikan bahwa secara rata-rata, persentase kesalahan atau penyimpangan proporsional antara hasil prediksi model terhadap kuantitas permintaan aktual konveksi di lapangan hanya sebesar 12,91%. Hal ini membuktikan bahwa akurasi model sudah sangat memadai dan reliabel untuk digunakan sebagai dasar pengambilan keputusan dalam estimasi stok bahan baku.

#### 4.4.2 MAE

Untuk mengukur magnitudo kesalahan dalam bentuk satuan unit riil, digunakan metrik *Mean Absolute Error* (MAE) yang menghasilkan nilai sebesar 149,61 unit. Nilai MAE sebesar 149,61 unit ini mengindikasikan bahwa rata-rata jarak atau selisih mutlak antara volume pesanan yang diprediksi oleh model dengan kuantitas pesanan riil di lapangan adalah sebesar 149,61 unit atribut pakaian, tanpa dipengaruhi oleh arah kesalahan (baik *overestimation* maupun *underestimation*). Nilai kesalahan absolut yang terukur ini dinilai masih berada dalam batas toleransi operasional yang wajar bagi industri konveksi skala massal.

#### 4.4.3 Analisis Grafik Evaluasi Data Uji

Untuk memvalidasi performa model secara visual, Gambar 3 menyajikan perbandingan antara data aktual (garis biru) dan hasil prediksi model (garis putus-putus oranye) pada 96 baris data pengujian.



**Gambar 3 Perbandingan aktual dan prediksi**

Grafik prediksi mampu mengikuti fluktuasi naik-turun data aktual secara sinkron dan presisi. Pola paling krusial terlihat pada indeks data uji ke-48, di mana terjadi lonjakan kuantum (*quantum leap*) volume permintaan dari kisaran di bawah 1.000 unit menjadi mendekati 3.000 unit. Kemampuan model dalam menangkap lompatan ekstrem ini membuktikan secara empiris bahwa penambahan fitur biner Tahun\_Ajaran\_Baru sukses memitigasi sifat kaku (*rigidity*) dari algoritma *Linear Regression* konvensional, sehingga model tidak mengalami *underfitting* saat menghadapi *peak season*.

## 5 Kesimpulan

Penelitian ini berhasil mengimplementasikan metode *Linear Regression* untuk memprediksi pemesanan atribut sekolah berdasarkan data historis periode 2021–2025. Hasil evaluasi menunjukkan nilai MAPE sebesar 12,91% dan MAE sebesar 149,61 unit, yang mengindikasikan bahwa model memiliki tingkat akurasi yang baik dalam memprediksi jumlah permintaan. Selain itu, variabel semester, jenis produk, dan periode tahun ajaran baru terbukti berpengaruh terhadap pola pemesanan. Dengan demikian, metode *Linear Regression* dapat digunakan sebagai solusi yang sederhana dan efektif untuk mendukung perencanaan produksi serta pengambilan keputusan pada industri konveksi atribut sekolah.

## Referensi

- [1] C. Ayu Fatikasari, A. Marsha Rahmania, il Laili, R. Ayu Mega Saputri, and M. Arifin, “Analisis Segmentasi dan Prediksi Pola Pembelian IC Label Gamis menggunakan *Hybrid K-Means Random Forest*,” *JUKTISI: Jurnal Komputer Teknologi Informasi Sistem Komputer*, Vol. 5, No. 1, pp. 355–364, 2026, DOI: 10.62712/juktisi.v5i1.1001.
- [2] G. Tamami and M. Arifin, “Penggunaan LSTM dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens,” *FASILKOM*, Vol. 14, No. 2, pp. 301–308, Aug. 2024, [Online]. Available: <https://www.kaggle.com/datasets/artakusuma/laptope>
- [3] I. Ramdhani, Raodah, and Erniyani, “Peramalan Permintaan Produk Bakso Frozen FA menggunakan Metode *Time Series*,” *Factory Jurnal Industri, Manajemen dan Rekayasa Sistem Industri*, Vol. 4, No. 2, pp. 105–112, Dec. 2025, DOI: 10.56211/factory.v4i2.1248.
- [4] W. O. Jeslin, T. W. Mawatdah, K. Limbong, and D. Vientiany, “Peran Anggaran Produksi dalam mengendalikan Biaya dan Menjaga Kelancaran Proses Operasional Perusahaan,” *Jurnal Ilmiah Manajemen dan Akuntansi*, Vol. 3, No. 2, pp. 32–41, Jan. 2026, DOI: <https://doi.org/10.69714/4eqcz654>.
- [5] A. Giawa, S. Kakisina, A. Telaumbanua, and H. Gulo, “Analisis Peramalan Penjualan Produk Telur untuk menentukan Persediaan pada CV. Monalisa Mitra Makmur Kota Gunungsoli,” *Jurnal Publikasi Manajemen Informatika*, Vol. 5, No. 2, pp. 40–53, Feb. 2026, DOI: 10.55606/jupumi.v5i2.6638.

- [6] F. A. Mardatillah and P. H. Suci, "Analisis Manajemen Produksi Usaha Konveksi di Muthia Konveksi Tanjung Beringin Pasaman," *Gorga : Jurnal Seni Rupa*, Vol. 13, No. 1, pp. 252–258, Jun. 2024.
- [7] F. H. Hamdanah and D. Fitrihanah, "Analisis Performansi Algoritma Linear Regression dengan *Generalized* Linear Model untuk Prediksi Penjualan pada Usaha Mikra, Kecil, dan Menengah," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, Vol. 10, No. 1, p. 23, Apr. 2021, DOI: 10.23887/janapati.v10i1.31035.
- [8] M. H. Permata, "Pengembangan Model Peramalan Penjualan *Fast Food* dengan *Xgboost* menggunakan *Python*," Bachelor's Thesis, Universitas Islam Negeri Syarif Hidayatullah Jakarta, Jakarta, 2024.
- [9] V. K. Setyo and M. Z. Abdillah, "Prediksi Tonase Penjualan PT. Immanuel Periode 2015-2024 dengan Metode *Triple Exponential Smoothing*," *Jurnal Pendidikan dan Teknologi Indonesia*, Vol. 4, No. 12, pp. 585–595, Dec. 2024, DOI: 10.52436/1.jpti.505.
- [10] M. R. E. Satria, D. Rosiani, A. D. Candra, and A. Setiyono, "Analisis Forecasting Produk Gas Menggunakan Algoritma Prophet Dan Arima," *SNTEM*, vol. 5, pp. 562–572, Nov. 2025.
- [11] Syalsabylla, U. Khaira, and M. F. Putri, "Forecasting Data Penjualan Harian Dea Bakery dengan Metode Sarima," *Jurnal ilmiah Sistem Informasi dan Ilmu Komputer*, Vol. 5, No. 3, pp. 168–185, Oct. 2025, DOI: 10.55606/juisik.v5i3.1611.
- [12] V. Sariayu and P. Sugiartawan, "Analisis Prediksi Penjualan Lampu dengan Metode SVM pada PT. Terang Abadi Raya," *Jurnal Sistem Informasi dan Komputer Terapan Indonesia (JSIKTI)*, Vol. 5, No. 1, pp. 1–10, Jun. 2023, DOI: 10.33173/jsikti.172.
- [13] A. N. Afiati, Prajoko, and F. F. Az-Zahra, "Implementasi Algoritma Regresi Linier dalam Predeksi Persediaan Voucher di Raffa Cell Sukabumi," *Jurnal Mahasiswa Teknik Informatika*, Vol. 8, No. 5, pp. 10801–10808, 2024.
- [14] Z. Ngabidin, A. Sanwidi, and E. R. Arini, "Implementasi Metode *Double Exponential Smoothing Brown* untuk Meramalkan Jumlah Penduduk Miskin," *Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi*, Vol. 11, No. 2, pp. 328–338, Dec. 2023, DOI: 10.37905/euler.v11i2.23054.
- [15] H. Mustafidah and S. N. Rohman, "Mean Square Error pada Metode Random dan Nguyen Widrow dalam Jaringan Syaraf Tiruan Mean Square Error on Random and Nguyen Widrow Method on Artificial Neural Networks," *Sainteks*, Vol. 20, No. 2, pp. 133–2, Oct. 2023, DOI: 10.30595/sainteks.v20i2.19516.