

# Penerapan ARIMA *Box-Jenkins* untuk Peramalan Penjualan Bulanan sebagai Dasar *Demand Planning* PT XYZ

<sup>1</sup>Zahra Zakiyatus Shalihah, <sup>2</sup>Hafiyyan Putra Pratama, <sup>3</sup>Wiyanto Wiyanto

<sup>1,2\*</sup>Sistem Telekomunikasi, Universitas Pendidikan Indonesia, Purwakarta, Indonesia

<sup>3</sup>Teknik Informatika, Universitas Pelita Bangsa, Bekasi, Indonesia

\*Korespondensi: [hafiyyan@upi.edu](mailto:hafiyyan@upi.edu)

Submit : 29 Jul 2026 | Diterima : 21 Agust 2026 | Terbit : 05 Sept 2026

## ABSTRACT

*Demand planning in the ceramic manufacturing industry relies on accurate sales estimation, as forecasting errors can lead to excess or insufficient inventory that burdens company operations. At the same time, PT XYZ has monthly sales data from January 2018 to February 2026 that has not been optimally used as a basis for statistically validated demand planning. This study aims to build and evaluate an Autoregressive Integrated Moving Average model based on the Box-Jenkins procedure as a sales forecasting tool for the company's monthly sales and to produce sales projections for March to December 2026 as a basis for demand planning. The study used 98 monthly sales observations divided into an estimation period and a 12-month out-of-sample evaluation period, with five candidate models formed from ACF and PACF patterns after stationarity was achieved (ADF on the first difference  $t = -3.749$ ,  $p = 0.0052$ ), then evaluated through parameter significance, Ljung-Box residual diagnostics, and four accuracy metrics: RMSE, MAE, MAPE, and Theil Inequality Coefficient. Results show that SARIMA(0,1,1)(1,0,0)<sub>12</sub> was selected as the best model because its parameters were significant and it was the only candidate satisfying the white noise residual assumption, generating sales projections ranging from 7,383,509 to 8,805,625 m<sup>2</sup>. The AR(12) component captured the annual seasonal pattern in monthly sales so that the model can serve as a baseline forecast supporting production planning, procurement, and inventory management. Further research is recommended to incorporate external variables or compare ARIMA with other forecasting methods for more adaptive demand planning.*

**Keywords:** *Box-Jenkins Procedure; Demand Planning; Sales Forecasting; Seasonal ARIMA; Time Series Analysis*

## ABSTRAK

Perencanaan permintaan pada industri manufaktur keramik sangat bergantung pada estimasi penjualan yang akurat karena ketidaktepatan peramalan dapat menimbulkan kelebihan atau kekurangan persediaan yang membebani operasional perusahaan. Sementara itu, PT XYZ memiliki data penjualan bulanan periode Januari 2018 sampai Februari 2026 yang belum dimanfaatkan secara optimal sebagai dasar *demand planning* berbasis model deret waktu yang telah teruji secara statistik. Penelitian ini bertujuan membangun dan mengevaluasi model *Autoregressive Integrated Moving Average* berbasis prosedur Box-Jenkins untuk meramalkan penjualan bulanan perusahaan serta menghasilkan proyeksi penjualan dari Maret sampai Desember 2026 sebagai dasar *perencanaan permintaan*. Penelitian menggunakan 98 observasi data penjualan bulanan yang dibagi menjadi periode estimasi dan periode evaluasi *out-of-sample* selama 12 bulan. Lima kandidat model dibentuk berdasarkan pola *Autocorrelation Function* dan *Partial Autocorrelation Function* pascastasioner (uji ADF pada first difference  $t = -3,749$ ,  $p = 0,0052$ ), kemudian dievaluasi melalui signifikansi parameter, diagnostik residual *Ljung-Box*, serta empat metrik akurasi, yaitu RMSE, MAE, MAPE, dan *Theil Inequality Coefficient*. Hasil penelitian menunjukkan bahwa SARIMA(0,1,1)(1,0,0)<sub>12</sub> terpilih sebagai model terbaik karena parameternya signifikan dan menjadi satu-satunya kandidat yang memenuhi asumsi residual *white noise*, dengan proyeksi penjualan pada kisaran 7.383.509 sampai 8.805.625 m<sup>2</sup> untuk periode Maret sampai Desember 2026. Penambahan komponen AR(12) mampu menangkap pola musiman tahunan pada data penjualan bulanan, sehingga model ini dapat digunakan sebagai *baseline forecast* untuk mendukung perencanaan produksi,

pengadaan bahan baku, dan pengelolaan persediaan di industri keramik. Penelitian selanjutnya disarankan untuk mengembangkan model dengan memasukkan variabel eksternal atau membandingkan ARIMA dengan metode peramalan lain agar hasil *demand planning* lebih adaptif terhadap perubahan kondisi bisnis.

**Kata Kunci:** Analisis Deret Waktu; ARIMA Musiman; Demand Planning; Peramalan Penjualan; Prosedur Box-Jenkins

## PENDAHULUAN

Perencanaan permintaan merupakan bagian penting dalam sistem operasional perusahaan manufaktur karena keputusan produksi, pengadaan bahan baku, pengelolaan persediaan, dan alokasi kapasitas sangat bergantung pada estimasi penjualan pada periode mendatang. Pada industri keramik, ketidaktepatan estimasi penjualan dapat menyebabkan ketidakseimbangan antara jumlah produksi dan kebutuhan pasar, yang berpotensi menimbulkan kelebihan persediaan atau kekurangan stok. Dengan demikian, *demand planning* perlu didukung oleh metode peramalan yang terukur agar keputusan operasional tidak hanya didasarkan pada intuisi, tetapi juga pada analisis data historis.

PT XYZ memiliki data penjualan bulanan dari Januari 2018 sampai Februari 2026 (98 observasi) yang belum dimanfaatkan secara optimal sebagai dasar *demand planning* berbasis model deret waktu yang telah teruji secara statistik. Tinjauan terhadap penelitian terdahulu menunjukkan dua keterbatasan yang berkaitan. Pertama, sebagian besar penerapan ARIMA dalam konteks penjualan dan manufaktur berhenti pada capaian akurasi peramalan dan belum menjembatani hasilnya ke dalam keputusan *demand planning* operasional (Sunendar & Rianto, 2025; Suryawan, Putra, Meliana, & Sudipa, 2024). Sebagian studi memang telah menautkan peramalan dengan keputusan operasional, misalnya integrasi ARIMA dengan *Economic Order Quantity* untuk menentukan persediaan pengaman dan titik pemesanan ulang (Syamsi, Irfan, Novaliendry, & Sandra, 2026). Namun, integrasi semacam ini masih relatif terbatas. Kedua, meskipun data penjualan industri kerap menunjukkan pola musiman tahunan, masih relatif sedikit studi yang secara eksplisit mengakomodasi komponen musiman melalui model SARIMA.

Kedua keterbatasan tersebut bermuara pada satu celah. Tanpa struktur musiman yang tepat, model peramalan menjadi kurang layak sebagai dasar perencanaan; sementara itu, model yang layak pun belum tentu diterjemahkan ke dalam keputusan operasional. Celah inilah yang mendasari penelitian ini, yakni menerapkan model ARIMA yang diperluas dengan komponen musiman (SARIMA) sebagai *baseline forecast* yang layak secara statistik untuk mendukung kebutuhan *demand planning* PT XYZ.

Metode *time series forecasting* banyak digunakan dalam peramalan penjualan dan permintaan berbasis data periodik karena kemampuannya membaca hubungan temporal, pola fluktuasi, dan pola musiman dari data historis (Ahaggach, Abrouk, & Lebon, 2024; Makridakis, Spiliotis, & Assimakopoulos, 2022). (Syahanifadhel, Basuki, Hasna, & Azzam, 2023) menunjukkan bahwa hasil peramalan dapat digunakan sebagai dasar penyusunan *Master Production Schedule* sehingga proses produksi dapat direncanakan secara lebih sistematis; (Qurniawan & Sukmono, 2025) menunjukkan bahwa metode peramalan berbasis ARIMA dapat digunakan untuk memperkirakan permintaan dan mendukung pengelolaan persediaan, sedangkan (Wang & Wang, 2025) menegaskan bahwa peramalan penjualan dapat membantu perencanaan persediaan dan jaringan penyimpanan.

Salah satu metode yang banyak digunakan untuk menghasilkan peramalan tersebut adalah *Autoregressive Integrated Moving Average* (ARIMA). Metode ini cocok digunakan ketika data yang dianalisis bersifat univariat dan fokus penelitian diarahkan pada pemanfaatan pola historis variabel itu sendiri. Pemilihan ARIMA dalam penelitian ini didasarkan pada karakter data berupa data bulanan dengan jumlah observasi terbatas, sehingga pendekatan statistik klasik yang sederhana, transparan, dan mudah diinterpretasikan lebih sesuai dibandingkan model *machine learning* yang umumnya membutuhkan data lebih besar dan proses komputasi lebih kompleks. (Suryawan et al., 2024) menunjukkan bahwa ARIMA masih dapat bersaing dengan LSTM dan Prophet pada kasus peramalan penjualan tertentu, sedangkan (Ozdemir & Yozgatligil, 2024) menjelaskan bahwa pemilihan metode peramalan perlu mempertimbangkan frekuensi data, horizon prediksi, dan karakteristik deret waktu yang dianalisis. Ketika data penjualan menunjukkan pola berulang tahunan, model ARIMA diperluas menjadi *Seasonal ARIMA* (SARIMA) yang mengakomodasi komponen musiman melalui notasi  $(P\ D\ Q)_s$ , sehingga mampu menangkap fluktuasi jangka pendek sekaligus pola tahunan secara bersamaan. Sejumlah studi

mengonfirmasi keunggulan SARIMA dibandingkan ARIMA non-musiman pada data bermuatan musiman, baik dari sisi galat peramalan maupun keandalan *baseline forecast* (Suseno & Suryo Wibowo, 2023; Zhao, 2024).

Penerapan ARIMA dan SARIMA sendiri telah dilakukan pada berbagai konteks penjualan dan produksi. (Prastio, Widhiono, Lestari, & Dharmawan, 2025) menggunakan ARIMA untuk meramalkan penjualan produk susu steril berbasis data bulanan, (Ahmar, Botto-Tobar, Rahman, & Hidayat, 2022) menerapkan ARIMA Box-Jenkins dalam peramalan nilai ekspor minyak dan gas Indonesia, serta (Permata & Habibi, 2023) menerapkan ARIMA pada produk fashion bermuatan musiman berupa celana jeans. Pada konteks yang lebih dekat dengan penelitian ini, (Dieny & Sutrisno, 2026) meramalkan produksi pada salah satu produsen keramik di Kota Malang dan menemukan bahwa model SARIMA memberikan akurasi tertinggi sebagai dasar perencanaan produksi, sementara (Firdaus, Komaro, & Dwiyantri, 2026) menemukan model SARIMA sebagai metode paling akurat dalam memprediksi permintaan produk fashion musiman pada sebuah perusahaan manufaktur, mengungguli metode Holt-Winters. Selanjutnya, (Rizki, Priyanto, Martono, Sulistianingsih, & Syahrir, 2025) menunjukkan keunggulan SARIMA dalam menangani kesalahan besar pada peramalan penjualan bermuatan musiman. (Chandra, 2023) menegaskan bahwa pendekatan Box-Jenkins perlu dilakukan secara bertahap melalui pengujian stasioneritas, identifikasi model, estimasi parameter, pemeriksaan diagnostik residual, dan evaluasi akurasi peramalan. Dengan demikian, penelitian ini tidak hanya bertujuan menghasilkan model SARIMA yang akurat secara statistik, tetapi juga merumuskan rekomendasi *demand planning* operasional yang terukur bagi PT XYZ berdasarkan hasil peramalan tersebut.

### METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode analisis deret waktu, mengikuti prosedur Box-Jenkins sebagaimana telah diuraikan pada bagian sebelumnya. Prosedur ini terdiri atas tahapan pengujian stasioneritas, identifikasi model, estimasi parameter, pemeriksaan diagnostik residual, hingga evaluasi akurasi peramalan. Metode ini dipilih karena data yang dianalisis berupa data penjualan bulanan yang tersusun secara kronologis, sehingga dapat digunakan untuk mengidentifikasi pola historis dan menghasilkan peramalan pada periode mendatang. Penggunaan ARIMA Box-Jenkins dalam pemodelan deret waktu juga telah diterapkan oleh (Ahmar et al., 2022; Chandra, 2023; Nurman, Nusrang, & Sudarmin, 2022).

Data yang digunakan dalam penelitian ini adalah data sekunder berupa volume penjualan bulanan PT XYZ pada periode Januari 2018 sampai Februari 2026. Data diperoleh melalui dokumentasi arsip dan basis data penjualan perusahaan. Jumlah data yang digunakan adalah 98 observasi bulanan, dengan variabel utama berupa volume penjualan bulanan yang dinotasikan sebagai  $Y_t$ . Volume penjualan bulanan dinyatakan dalam satuan meter persegi ( $m^2$ ), mengikuti konvensi umum penjualan produk keramik yang diukur berdasarkan luasan pemasangan. Nama perusahaan yang digunakan dalam penelitian ini (PT XYZ) merupakan nama samaran untuk menjaga kerahasiaan data sesuai kesepakatan dengan pihak perusahaan. Sebagai bagian dari perlindungan kerahasiaan tersebut, data yang digunakan dalam penelitian telah melalui proses anonimisasi/transformatasi untuk melindungi informasi bisnis yang sensitif. Proses tersebut mempertahankan karakteristik statistik dan pola deret waktu data asli. Data dibagi menjadi dua bagian, yaitu data estimasi dan data evaluasi. Periode Januari 2018 sampai Februari 2025 digunakan sebagai data estimasi model, sedangkan periode Maret 2025 sampai Februari 2026 digunakan sebagai data evaluasi *out-of-sample*. Setelah proses *first differencing*, jumlah observasi efektif pada tahap estimasi menjadi 85 karena satu observasi awal digunakan untuk membentuk selisih pertama. Pembagian data ini dilakukan agar model tidak hanya dinilai berdasarkan data pembentukan model, tetapi juga diuji kemampuannya dalam meramalkan periode yang tidak digunakan pada tahap estimasi. Seluruh tahap pemodelan yang meliputi pengujian stasioneritas, identifikasi melalui korelogram, estimasi parameter, pemeriksaan diagnostik residual, dan evaluasi akurasi *out-of-sample* dilakukan sepenuhnya pada sampel estimasi periode Januari 2018 sampai Februari 2025, agar informasi dari periode evaluasi tidak memengaruhi proses pembentukan model (*look-ahead bias*). Model ARIMA secara umum dinyatakan sebagai berikut:

$$\phi(B)(1 - B)^d Y_t = \theta(B)\epsilon_t$$


Pada persamaan tersebut,  $Y_t$  merupakan nilai penjualan pada periode ke- $t$ ,  $B$  merupakan operator lag,  $d$  menunjukkan orde *differencing*,  $\phi(B)$  menunjukkan komponen *autoregressive*,

$\theta(B)$  menunjukkan komponen *moving average*, dan  $\varepsilon_t$  merupakan komponen galat. Spesifikasi model dituliskan tanpa konstanta untuk menjaga prinsip parsimoni dalam prosedur Box-Jenkins. Lebih lanjut, untuk mengakomodasi pola musiman tahunan pada data penjualan, model ARIMA tersebut dikembangkan menjadi model SARIMA (*Seasonal ARIMA*) dengan notasi umum  $(p\ d\ q)(P\ D\ Q)_s$ . Dalam penelitian ini, penggunaan komponen musiman  $(P\ D\ Q)_{12}$  memungkinkan model untuk mengintegrasikan pengaruh ketergantungan observasi pada bulan yang sama di tahun sebelumnya ke dalam struktur peramalan, sehingga memberikan representasi data yang lebih komprehensif dibandingkan model ARIMA non-musiman. Estimasi parameter dilakukan dengan metode *Maximum Likelihood Estimation* pada perangkat lunak EViews 12.

Pengujian stasioneritas dilakukan menggunakan uji *Augmented Dickey-Fuller* (ADF). Apabila data belum stasioner pada level, maka dilakukan proses *differencing* hingga data memenuhi syarat stasioneritas. Data dinyatakan stasioner apabila nilai probabilitas ADF lebih kecil dari taraf signifikansi 5%. Penentuan orde *differencing* (d) tidak hanya didasarkan pada hasil uji *Augmented Dickey-Fuller*, tetapi juga mempertimbangkan pola korelogram dan kelayakan model yang dihasilkan, sebagaimana diuraikan pada bagian Hasil dan Pembahasan.

Setelah data memenuhi syarat stasioneritas, identifikasi model dilakukan dengan memperhatikan pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Berdasarkan pola tersebut, beberapa kandidat model ARIMA dibentuk dan kemudian diestimasi. Kandidat model yang diuji dalam penelitian ini meliputi ARIMA(0,1,1), ARIMA(1,1,0), ARIMA(1,1,1), ARIMA(2,1,0), dan SARIMA(0,1,1)(1,0,0)<sub>12</sub>. Penambahan komponen AR(12) dilakukan untuk menangkap kemungkinan adanya pola musiman tahunan pada data penjualan bulanan. Estimasi parameter dilakukan untuk memperoleh nilai signifikansi koefisien AR dan MA, kemudian diuji untuk menilai signifikansi keduanya pada taraf 5%. Model dengan parameter yang tidak signifikan tidak diprioritaskan dalam pemilihan model akhir karena tidak memenuhi prinsip kelayakan statistik dan parsimoni. Setelah model terbaik ditetapkan berdasarkan sampel estimasi, model tersebut diestimasi ulang (*re-estimated*) menggunakan seluruh data aktual periode Januari 2018 sampai Februari 2026 untuk menghasilkan proyeksi penjualan pada periode Maret sampai Desember 2026. Estimasi ulang ini bertujuan untuk memanfaatkan seluruh informasi historis yang tersedia sebelum melakukan peramalan ke depan, sementara evaluasi akurasi model tetap didasarkan pada pengujian *out-of-sample* pada sampel estimasi.

Tahapan pemodelan dalam penelitian ini dapat diringkas melalui alur berikut.



Gambar 1. Alur Pemodelan ARIMA Berbasis Prosedur Box-Jenkins

Setelah tahap estimasi, dilakukan pemeriksaan diagnostik residual menggunakan uji *Ljung-Box*. Uji ini bertujuan untuk memastikan bahwa residual model bersifat *white noise* atau tidak lagi mengandung autokorelasi yang signifikan. Model dinyatakan lolos diagnostik apabila nilai probabilitas uji *Ljung-Box* lebih besar dari 0,05. Pemeriksaan residual menjadi penting karena model ARIMA yang baik tidak hanya menghasilkan nilai galat yang rendah, tetapi juga harus mampu menangkap pola data sehingga residualnya tidak lagi berpola. Penggunaan uji *Ljung-Box* dalam evaluasi residual ARIMA juga digunakan oleh (Chandra, 2023) serta (Rizqullah, 2025). Rumus uji *Ljung-Box* dinyatakan sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{n-k}$$

Pada rumus tersebut,  $Q$  merupakan statistik *Ljung-Box*,  $n$  adalah jumlah observasi,  $m$  adalah jumlah lag yang diuji, dan  $\hat{\rho}_k$  adalah autokorelasi residual pada lag ke- $k$ . Dalam penelitian ini, pemeriksaan residual dilakukan pada  $Q(12)$  dan  $Q(36)$  untuk melihat apakah residual masih mengandung pola autokorelasi pada satu siklus tahunan maupun pada horizon lag yang lebih panjang.

Evaluasi akurasi peramalan dilakukan menggunakan data *out-of-sample* pada periode Maret 2025 sampai Februari 2026. Ukuran akurasi utama yang digunakan adalah *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan *Theil Inequality Coefficient* atau Theil U1. RMSE digunakan untuk menilai besarnya galat dengan penalti yang lebih besar terhadap kesalahan ekstrem, MAE digunakan untuk mengukur rata-rata kesalahan absolut, MAPE digunakan untuk membaca kesalahan dalam bentuk persentase, sedangkan Theil U1 digunakan untuk melihat ketimpangan relatif antara nilai aktual dan hasil peramalan. Penggunaan beberapa metrik secara bersamaan diperlukan agar pemilihan model tidak hanya bergantung pada satu ukuran galat, tetapi juga mempertimbangkan karakteristik kesalahan peramalan dari beberapa sudut pandang (Chandra, 2023; Rizqullah, 2025). Rumus RMSE, MAE, dan MAPE dinyatakan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2}$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t|$$

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|$$

Pada rumus tersebut,  $Y_t$  merupakan nilai aktual,  $\hat{Y}_t$  merupakan nilai hasil peramalan, dan  $n$  merupakan jumlah periode evaluasi.

Pemilihan model akhir dilakukan secara bertahap. Tahap pertama adalah melihat signifikansi parameter dalam model. Tahap kedua adalah memastikan residual model memenuhi asumsi *white noise* melalui uji *Ljung-Box*. Tahap ketiga adalah membandingkan nilai RMSE, MAE, MAPE, dan Theil U1 pada data *out-of-sample*. Apabila terdapat perbedaan arah hasil antarmetrik, MAPE digunakan sebagai pertimbangan utama karena lebih mudah diinterpretasikan dalam konteks bisnis. Model terbaik kemudian dinilai relevansinya terhadap kebutuhan *demand planning*, terutama untuk mendukung perencanaan produksi, pengadaan bahan baku, serta pengelolaan persediaan perusahaan.

Seluruh proses pengolahan data dilakukan menggunakan perangkat lunak EViews 12. Perangkat lunak ini digunakan untuk melakukan uji stasioneritas, estimasi model ARIMA, pemeriksaan diagnostik residual, serta evaluasi akurasi peramalan.

## HASIL DAN PEMBAHASAN

### Uji Stasioneritas Data

Tahap awal dalam pemodelan ARIMA adalah memastikan data penjualan bulanan memenuhi asumsi stasioneritas. Pengujian dilakukan menggunakan *Augmented Dickey-Fuller*

(ADF) pada tingkat *first difference*, dengan hasil yang disajikan pada Tabel 1.

Tabel 1 Hasil Uji Stasioneritas *Augmented Dickey-Fuller* (ADF) pada Sampel Estimasi 2018M01-2025M02

| Variabel  | ADF t-Statistic | p-value | Keterangan                                |
|-----------|-----------------|---------|-------------------------------------------|
| D(HSALES) | -3,749          | 0,0052  | Stasioner setelah <i>first difference</i> |

Sumber: Hasil pengolahan data menggunakan EViews 12. Pengujian menggunakan *intercept*, dengan panjang lag yang ditentukan secara otomatis berdasarkan Schwarz Information Criterion.


Berdasarkan Tabel 1, uji ADF pada *first difference* menghasilkan nilai t sebesar -3,749 dengan p-value 0,0052, yang lebih kecil dari taraf signifikansi 5%, sehingga data hasil *first difference* dinyatakan stasioner. Penetapan orde integrasi  $d = 1$  didasarkan pada pemeriksaan korelogram yang memperlihatkan struktur ketergantungan musiman tahunan yang kuat, ditandai dengan korelasi tinggi pada lag ke-12 (sebesar 0,502, Q-statistik 58,597, p-value 0,000), serta pada pertimbangan kelayakan model dalam kerangka iteratif Box-Jenkins.

### Identifikasi Model

Setelah data dinyatakan stasioner melalui uji ADF, tahap selanjutnya adalah mengidentifikasi orde model dengan mengamati pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) pada korelogram data hasil *first difference*. Sebagaimana uji ADF menggunakan taraf signifikansi 5% sebagai dasar pengambilan keputusan, identifikasi pada tahap ini menggunakan garis batas signifikansi pada korelogram sebagai acuan. Suatu lag dinyatakan signifikan apabila nilai autokorelasinya melampaui garis batas tersebut, dan sebaliknya dianggap tidak signifikan apabila nilainya berada di dalam garis batas tersebut. Dengan demikian, penentuan orde model tidak dilakukan secara subjektif, melainkan berdasarkan kriteria yang dapat diamati secara langsung pada korelogram.

Pengamatan difokuskan pada dua struktur, yaitu struktur jangka pendek pada lag-lag awal dan struktur musiman pada lag ke-12. Pada struktur jangka pendek, ACF menunjukkan nilai yang signifikan pada lag 1 sebesar -0,531, kemudian menurun tajam dan berada di dalam garis batas mulai lag 2 sebesar 0,084. Pola autokorelasi yang terputus setelah lag 1 ini mengindikasikan keberadaan komponen *Moving Average* orde satu, MA(1).

Adapun pada struktur musiman, ACF kembali menunjukkan nilai yang tinggi dan signifikan pada lag ke-12 sebesar 0,502, dengan Q-statistik 58,597 dan p-value <0,001. Mengingat lag ke-12 merepresentasikan satu siklus tahunan pada data bulanan, autokorelasi yang menonjol pada titik ini menandakan adanya ketergantungan musiman tahunan, sehingga model dilengkapi dengan komponen *Autoregressive* musiman, AR(12). Pemilihan AR(12) sebagai komponen musiman terbukti memadai karena mampu menyerap pola musiman tahunan sehingga residual model memenuhi asumsi *white noise* pada tahap diagnostik. Meskipun terdapat beberapa lag lain yang juga melewati garis signifikansi, lag-lag tersebut berada di sekitar titik musiman (lag 12) dan tidak dimodelkan secara terpisah untuk menjaga kesederhanaan model. Pola ACF dan PACF selengkapnya ditampilkan pada Gambar 2.

Gambar 2. Korelogram ACF dan PACF D(HSALES) setelah *First Differencing***Estimasi Parameter Model ARIMA**

Setelah kandidat model diperoleh, tahap berikutnya adalah mengestimasi parameter. Estimasi dilakukan untuk menilai signifikansi parameter AR dan MA pada masing-masing kandidat model. Hasil estimasi parameter disajikan pada Tabel 2.

Tabel 2 Hasil Estimasi Parameter Model ARIMA Kandidat

| Model                              | Parameter | Coefficient | SE     | t-Statistic | p-value | AIC     | SBC     |
|------------------------------------|-----------|-------------|--------|-------------|---------|---------|---------|
| ARIMA(0,1,1)                       | MA(1)     | -0,9103     | 0,0485 | -18,754     | <0,001  | 32,0042 | 32,0617 |
| SARIMA(0,1,1)(1,0,0) <sub>12</sub> | AR(12)    | 0,5407      | 0,0798 | 6,779       | <0,001  | 31,7179 | 31,8041 |
| SARIMA(0,1,1)(1,0,0) <sub>12</sub> | MA(1)     | -0,8362     | 0,0530 | -15,784     | <0,001  |         |         |
| ARIMA(1,1,0)                       | AR(1)     | -0,5319     | 0,0778 | -6,833      | <0,001  | 32,2119 | 32,2693 |
| ARIMA(1,1,1)                       | AR(1)     | 0,0687      | 0,1161 | 0,592       | 0,5556  | 32,0243 | 32,1105 |
| ARIMA(1,1,1)                       | MA(1)     | -0,9303     | 0,0503 | -18,478     | <0,001  |         |         |
| ARIMA(2,1,0)                       | AR(1)     | -0,6823     | 0,0936 | -7,290      | <0,001  | 32,1541 | 32,2403 |
| ARIMA(2,1,0)                       | AR(2)     | -0,2791     | 0,1096 | -2,546      | 0,0128  |         |         |

Sumber: Hasil pengolahan data menggunakan EViews 12

Berdasarkan Tabel 2, seluruh parameter pada model SARIMA(0,1,1)(1,0,0)<sub>12</sub> signifikan secara statistik pada taraf 5%, yaitu AR(12) dengan koefisien 0,5407 (p-value <0,001) dan MA(1) dengan koefisien -0,8362 (p-value <0,001). Signifikansi parameter AR(12) mengonfirmasi bahwa pola musiman tahunan merupakan elemen penting dalam struktur data penjualan PT XYZ. Model ini juga menunjukkan nilai *Akaike Information Criterion* (AIC) dan *Schwarz Criterion* (SBC) terendah di antara seluruh kandidat, masing-masing sebesar 31,7179 dan 31,8041, yang memperkuat kelayakannya berdasarkan kriteria informasi.

Berbeda dengan kandidat lainnya, model ARIMA(1,1,1) memiliki parameter AR(1) yang tidak signifikan dengan p-value sebesar 0,5556, sehingga tidak memberikan kontribusi statistik yang signifikan. Berdasarkan prinsip parsimoni dalam prosedur Box-Jenkins, model dengan parameter yang tidak signifikan tidak diprioritaskan sebagai model akhir.

### Pemeriksaan Diagnostik Residual

Pemeriksaan diagnostik residual dilakukan menggunakan uji *Ljung-Box* untuk memastikan bahwa residual model bersifat *white noise*. Model dinyatakan memenuhi asumsi diagnostik apabila nilai p-value lebih besar dari 0,05. Hasil uji *Ljung-Box* disajikan pada Tabel 3.

Tabel 3 Hasil Uji Diagnostik Residual Menggunakan *Ljung-Box*

| Model                              | Q(12)  | p-value | Q(36)  | p-value |
|------------------------------------|--------|---------|--------|---------|
| ARIMA(0,1,1)                       | 32,389 | 0,001   | 85,468 | <0,001  |
| SARIMA(0,1,1)(1,0,0) <sub>12</sub> | 4,840  | 0,902   | 45,916 | 0,083   |
| ARIMA(1,1,0)                       | 44,198 | <0,001  | 114,21 | <0,001  |
| ARIMA(1,1,1)                       | 30,588 | 0,001   | 81,556 | <0,001  |
| ARIMA(2,1,0)                       | 34,352 | <0,001  | 82,773 | <0,001  |

Sumber: Hasil pengolahan data menggunakan EVIEWS 12. Nilai p yang sangat kecil ditulis <0,001.

Berdasarkan Tabel 3, hanya model SARIMA(0,1,1)(1,0,0)<sub>12</sub> yang memenuhi asumsi residual *white noise*. Model tersebut menghasilkan p-value sebesar 0,902 pada Q(12) dan 0,083 pada Q(36), keduanya lebih besar dari 0,05, sehingga residualnya tidak lagi menunjukkan autokorelasi yang signifikan. Sebaliknya, seluruh kandidat lain memiliki p-value lebih kecil dari 0,05 baik pada Q(12) maupun Q(36), yang menunjukkan residualnya masih berpola.

Temuan ini menunjukkan bahwa penambahan komponen AR(12) berperan penting dalam menangkap pola tahunan pada data penjualan bulanan. Hal ini diperkuat oleh pola kegagalan yang konsisten pada keempat kandidat non-musiman, yaitu autokorelasi residual yang signifikan selalu muncul pada *lag* ke-12. Dalam prosedur Box-Jenkins, model yang layak tidak hanya ditentukan oleh signifikansi parameter, tetapi juga oleh kemampuannya menghasilkan residual yang tidak berpola, sehingga SARIMA(0,1,1)(1,0,0)<sub>12</sub> menjadi satu-satunya kandidat yang lolos pada tahap diagnostik ini (Chandra, 2023; Rizqullah, 2025).

### Evaluasi Akurasi Peramalan Out-of-Sample

Model yang telah diestimasi kemudian dievaluasi menggunakan data *out-of-sample* pada periode Maret 2025 sampai Februari 2026. Evaluasi dilakukan menggunakan empat metrik utama, yaitu RMSE, MAE, MAPE, dan Theil U1. Hasil evaluasi akurasi disajikan pada Tabel 4.

Tabel 4 Evaluasi Akurasi Peramalan pada Sampel Out-of-Sample (dalam m<sup>2</sup>)

| Model                              | RMSE      | MAE       | MAPE (%) | Theil U1 |
|------------------------------------|-----------|-----------|----------|----------|
| ARIMA(0,1,1)                       | 1.677.782 | 1.484.474 | 18,198   | 0,0891   |
| SARIMA(0,1,1)(1,0,0) <sub>12</sub> | 1.435.253 | 1.217.054 | 14,971   | 0,0779   |
| ARIMA(1,1,0)                       | 1.946.488 | 1.792.983 | 21,761   | 0,1017   |
| ARIMA(1,1,1)                       | 1.756.449 | 1.569.303 | 19,196   | 0,0929   |
| ARIMA(2,1,0)                       | 1.601.979 | 1.434.911 | 17,525   | 0,0853   |

Sumber: Hasil pengolahan data menggunakan EVIEWS 12

Tabel 4 menunjukkan bahwa model SARIMA(0,1,1)(1,0,0)<sub>12</sub> menghasilkan nilai terendah pada seluruh metrik akurasi dibandingkan kandidat lain, yaitu RMSE sebesar 1.435.253 m<sup>2</sup>, MAE sebesar 1.217.054 m<sup>2</sup>, MAPE sebesar 14,971%, dan Theil U1 sebesar 0,0779. Nilai RMSE dan MAE yang paling kecil menunjukkan galat absolut yang lebih rendah dalam satuan volume penjualan, sedangkan MAPE sebesar 14,971% menunjukkan tingkat kesalahan persentase yang lebih rendah sehingga lebih mudah diinterpretasikan dalam konteks bisnis. Nilai Theil U1 sebesar 0,0779 juga menunjukkan ketimpangan relatif paling kecil antara nilai aktual dan hasil peramalan. Meskipun demikian, penelitian ini tidak menguji signifikansi statistik perbedaan akurasi antarmodel, misalnya melalui uji *Diebold-Mariano*, sehingga keunggulan tersebut bersifat deskriptif dan menjadi arah pengujian lanjutan.

### Pemilihan Model Akhir dan Pembahasan

Berdasarkan keseluruhan tahapan pemodelan, model SARIMA(0,1,1)(1,0,0)<sub>12</sub> terpilih sebagai model akhir karena memenuhi empat kriteria sekaligus, yaitu parameter yang signifikan, residual yang memenuhi asumsi *white noise*, nilai AIC dan SBC terendah, serta akurasi peramalan *out-of-sample* terbaik. Dengan demikian, pemilihan model tidak hanya didasarkan pada nilai galat terendah, tetapi juga pada kelayakan statistik secara menyeluruh dalam kerangka prosedur Box-Jenkins.

Secara substantif, komponen MA(1) menunjukkan adanya pengaruh galat pada periode sebelumnya terhadap perubahan penjualan pada periode saat ini. Sementara itu, komponen AR(12) menunjukkan adanya keterkaitan antara pola penjualan dan periode tahunan sebelumnya. Koefisien AR(12) sebesar 0,5407 menunjukkan bahwa sekitar setengah dari pola penjualan bulan yang sama pada tahun sebelumnya masih terbawa ke penjualan bulan berjalan, sementara koefisien MA(1) sebesar -0,8362 menunjukkan koreksi yang cukup kuat terhadap galat peramalan pada bulan sebelumnya. Hal ini relevan karena data yang digunakan merupakan data bulanan, sehingga kemungkinan adanya pola tahunan perlu dipertimbangkan. Temuan ini sejalan dengan prinsip pemodelan ARIMA yang menempatkan proses identifikasi, estimasi, diagnostik residual, dan evaluasi akurasi sebagai tahapan yang saling melengkapi dalam memilih model terbaik (Ahmar et al., 2022; Chandra, 2023; Nurman et al., 2022).

Hasil penelitian ini juga sejalan dengan studi (Prastio et al., 2025) serta (Qurniawan & Sukmono, 2025) yang menunjukkan bahwa ARIMA dapat digunakan untuk memodelkan data penjualan dan permintaan berbasis deret waktu. Berbeda dari kedua studi tersebut, penelitian ini menambahkan penekanan eksplisit pada relevansi hasil peramalan terhadap *demand planning*, tanpa berhenti pada capaian akurasi statistik semata. Dengan nilai MAPE paling rendah dan residual yang memenuhi asumsi *white noise*, SARIMA(0,1,1)(1,0,0)<sub>12</sub> memenuhi syarat sebagai model akhir untuk menghasilkan proyeksi penjualan pada periode berikutnya.

Temuan ini menjawab celah penelitian yang telah diidentifikasi pada bagian pendahuluan, yaitu perlunya penggunaan ARIMA yang tidak hanya berorientasi pada akurasi peramalan, tetapi juga mempertimbangkan kelayakan statistik model serta keterkaitannya dengan kebutuhan *demand planning*. Dengan terpilihnya SARIMA(0,1,1)(1,0,0)<sub>12</sub>, penelitian ini menunjukkan bahwa hasil peramalan dapat digunakan sebagai *baseline forecast* yang lebih terukur untuk mendukung perencanaan produksi, pengadaan bahan baku, dan pengelolaan persediaan di industri keramik.


### Hasil Peramalan Penjualan Maret-Desember 2026

Setelah model SARIMA(0,1,1)(1,0,0)<sub>12</sub> ditetapkan sebagai model terbaik, model tersebut diestimasi ulang menggunakan seluruh data aktual periode Januari 2018 sampai Februari 2026, kemudian digunakan untuk menghasilkan proyeksi penjualan bulanan PT XYZ untuk periode Maret sampai Desember 2026. Hasil estimasi ulang menunjukkan parameter yang stabil dan konsisten dengan hasil pada sampel estimasi, yaitu AR(12) sebesar 0,5187 dan MA(1) sebesar -0,8443, keduanya signifikan pada taraf 1%. Hasil peramalan disajikan pada Tabel 5.

Tabel 5 Hasil Peramalan Penjualan Maret-Desember 2026 (dalam m<sup>2</sup>)

| Periode        | Forecast Penjualan |
|----------------|--------------------|
| Maret 2026     | 7.383.509          |
| April 2026     | 8.155.068          |
| Mei 2026       | 8.131.659          |
| Juni 2026      | 8.030.972          |
| Juli 2026      | 8.805.625          |
| Agustus 2026   | 8.319.256          |
| September 2026 | 8.433.318          |
| Oktober 2026   | 8.629.805          |
| November 2026  | 8.532.203          |
| Desember 2026  | 8.053.585          |

Sumber: Hasil pengolahan data menggunakan EViews 12.



Gambar 3. Grafik Hasil Peramalan Penjualan Maret-Desember 2026

Berdasarkan Tabel 5 dan Gambar 3, hasil peramalan menunjukkan bahwa penjualan bulanan PT XYZ pada periode Maret-Desember 2026 diperkirakan berada pada kisaran 7.383.509 hingga 8.805.625 m<sup>2</sup>. Nilai peramalan tertinggi terjadi pada Juli 2026 sebesar 8.805.625 m<sup>2</sup>, sedangkan nilai terendah terjadi pada Maret 2026 sebesar 7.383.509 m<sup>2</sup>. Pola peramalan tidak menunjukkan kenaikan yang sepenuhnya linear, melainkan bergerak secara fluktuatif mengikuti pola musiman. Kondisi ini sejalan dengan karakter permintaan produk keramik yang tidak bersifat harian seperti barang kebutuhan pokok, melainkan dipengaruhi oleh proyek, kebutuhan renovasi, siklus pembelian distributor, dan kondisi pasar.

Hasil peramalan tersebut perlu dipahami sebagai *baseline forecast*, bukan sebagai angka produksi yang harus diikuti secara mutlak. Dalam bisnis keramik, terdapat keterkaitan langsung antara fungsi produksi dan fungsi penjualan, karena hasil peramalan dapat membantu perusahaan mengantisipasi kebutuhan kapasitas, stok, dan distribusi pada periode mendatang (Syahanifadhel et al., 2023; Wang & Wang, 2025). Apabila produksi dilakukan terlalu besar sementara penjualan tidak mampu menyerapnya, perusahaan berisiko mengalami kelebihan persediaan dan peningkatan biaya penyimpanan. Sebaliknya, apabila permintaan meningkat tetapi produksi tidak siap memenuhi kebutuhan tersebut, perusahaan dapat menghadapi risiko kekurangan stok dan kehilangan peluang penjualan. Oleh karena itu, hasil *forecast* digunakan sebagai dasar awal untuk menyusun skenario produksi, pengadaan bahan baku, pengendalian persediaan, serta strategi penjualan bulanan.

Karena model ARIMA yang digunakan bersifat univariat, hasil peramalan tetap perlu ditafsirkan secara hati-hati, diperbarui secara berkala, dan dikombinasikan dengan informasi aktual dari bagian produksi, penjualan, distributor, serta kondisi pasar.

### Batasan Studi

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Pertama, model yang digunakan bersifat univariat, sehingga hanya memanfaatkan pola historis penjualan dan tidak memasukkan variabel eksternal seperti harga, promosi, inflasi, kondisi ekonomi, maupun perubahan proyek konstruksi yang dapat memengaruhi permintaan keramik. Kedua, nilai *p-value Ljung-Box* pada  $Q(36)$  yang relatif dekat dengan taraf signifikansi 5%. Ketiga, penelitian ini tidak menguji signifikansi statistik perbedaan akurasi antarmodel, sehingga keunggulan model terpilih bersifat deskriptif. Oleh karena itu, hasil peramalan sebaiknya digunakan sebagai dasar awal *demand planning* dan tetap dikombinasikan dengan pertimbangan manajerial serta pembaruan data secara berkala.

### KESIMPULAN

Penelitian ini bertujuan untuk membangun dan mengevaluasi model ARIMA berbasis prosedur Box-Jenkins dalam meramalkan penjualan bulanan PT XYZ sebagai dasar *demand planning*. Berdasarkan hasil pengujian, data penjualan dinyatakan stasioner setelah proses *first differencing* dengan nilai ADF *t*-statistic sebesar -3,749 dan *p-value* 0,0052, sehingga model dibentuk dengan orde integrasi  $d = 1$ . Dari lima kandidat model yang diuji, model SARIMA(0,1,1)(1,0,0)<sub>12</sub> terpilih sebagai model terbaik karena memiliki parameter yang signifikan, menjadi satu-satunya model yang memenuhi asumsi residual *white noise*, memiliki nilai AIC dan SBC terendah, serta menghasilkan akurasi terbaik pada data *out-of-sample* dengan RMSE

sebesar 1.435.253 m<sup>2</sup>, MAE sebesar 1.217.054 m<sup>2</sup>, MAPE sebesar 14,971%, dan Theil U1 sebesar 0,0779. Model terpilih kemudian diestimasi ulang menggunakan seluruh data aktual untuk menghasilkan proyeksi penjualan periode Maret-Desember 2026, dengan nilai peramalan berada pada kisaran 7.383.509 sampai 8.805.625 m<sup>2</sup>. Hasil tersebut menunjukkan bahwa penambahan komponen AR(12) mampu menangkap pola musiman tahunan pada data penjualan bulanan, sehingga model ini dapat digunakan sebagai *baseline forecast* untuk mendukung perencanaan produksi, pengadaan bahan baku, pengelolaan persediaan, serta koordinasi antara fungsi produksi dan penjualan. Dengan demikian, penelitian ini menjawab kesenjangan penelitian dengan mengintegrasikan pemilihan model yang layak secara statistik dan pemanfaatan hasil peramalan untuk mendukung keputusan operasional dalam *demand planning* industri keramik. Namun, karena model bersifat univariat dan belum memasukkan variabel eksternal seperti harga, promosi, kondisi ekonomi, maupun perubahan permintaan pasar, hasil peramalan tetap perlu diperbarui secara berkala dan dikombinasikan dengan pertimbangan manajerial. Penelitian selanjutnya dapat mengembangkan model dengan memasukkan variabel eksternal atau membandingkan ARIMA dengan metode peramalan lain agar hasil *demand planning* lebih adaptif terhadap perubahan kondisi bisnis.

## REFERENSI

- Ahaggach, H., Abrouk, L., & Lebon, E. (2024). Systematic Mapping Study of Sales Forecasting: Methods, Trends, and Future Directions. *Forecasting*, 6(3), 502–532. <https://doi.org/10.3390/forecast6030028>
- Ahmar, A. S., Botto-Tobar, M., Rahman, A., & Hidayat, R. (2022). Forecasting the Value of Oil and Gas Exports in Indonesia using ARIMA Box-Jenkins. *JINAV: Journal of Information and Visualization*, 3(1), 35–42. <https://doi.org/10.35877/454RI.jinav260>
- Chandra, R. P. (2023). Econometric Modeling for High Impact Sustainable Organic Tea Production: The Box-Jenkins Approach. *Asian Journal of Economics, Business and Accounting*, 23(24), 141–154. <https://doi.org/10.9734/ajeba/2023/v23i241193>
- Dieny, A. R., & Sutrisno, T. F. (2026). Production Planning Forecasting using Seasonal and Non-Seasonal ARIMA Method with Minitab Applications (Study Case: DC Company). *Journal of Economics and Management Sciences*, 394–403. <https://doi.org/10.37034/jems.v8i2.259>
- Firdaus, F., Komaro, M., & Dwiyantri, V. (2026). Perbandingan Metode Holt-Winters dan SARIMA untuk Memprediksi Permintaan Produk Fashion pada PT XYZ. *Factory Jurnal Industri, Manajemen Dan Rekayasa Sistem Industri*, 4(2), 287–308. <https://doi.org/10.56211/factory.v4i2.1401>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*, 38(4), 1346–1364. <https://doi.org/10.1016/j.ijforecast.2021.11.013>
- Nurman, S., Nusrang, M., & Sudarmin. (2022). Analysis of Rice Production Forecast in Maros District Using the Box-Jenkins Method with the ARIMA Model. *ARRUS Journal of Mathematics and Applied Science*, 2(1), 36–48. <https://doi.org/10.35877/mathscience731>
- Ozdemir, O., & Yozgatligil, C. (2024). Forecasting performance of machine learning, time series, and hybrid methods for low- and high-frequency time series. *Statistica Neerlandica*, 78(2), 441–474. <https://doi.org/10.1111/stan.12326>
- Permata, J. M. A. C., & Habibi, M. (2023). Autoregressive Integrated Moving Average (ARIMA) Models For Forecasting Sales Of Jeans Products. *Telematika*, 20(1), 31. <https://doi.org/10.31315/telematika.v20i1.7868>
- Prastio, A. B., Widhiono, I., Lestari, S., & Dharmawan, B. (2025). Peramalan Penjualan Produk Susu Steril PT XYZ di Pasar Jakarta Tahun 2025 Menggunakan Model ARIMA (Autoregressive Integrated Moving Average): Sales Forecast for PT XYZ's Sterilized Milk Products in the Jakarta Market for 2025 Using the ARIMA (Autoregressive Integrated Moving Average) Model. *Journal of Integrated Agribusiness*, 7(1), 89–100. <https://doi.org/10.33019/jia.v7i1.6347>
- Qurniawan, N. T., & Sukmono, T. (2025). Peramalan Permintaan dengan Menerapkan Metode Autoregressive Integrated Moving Average (ARIMA) pada Industri Beton. 4(3), 1024–1032. <https://doi.org/10.55826/jtmit.v4i3.1117>

- Rizki, M., Priyanto, D., Martono, G. H., Sulistianingsih, N., & Syahrir, M. (2025). Perbandingan Algoritma Sarima dan Prophet Untuk Peramalan Trend Penjualan Voucher Game Online. *Jurnal Minfo Polgan*, 14(2), 1587–1598. <https://doi.org/10.33395/jmp.v14i2.15083>
- Rizqullah, M. A. (2025). *ANALISIS FORECASTING PERMINTAAN PRODUK MENGGUNAKAN METODE ARIMA (AUTOREGRESSIVE INTEGRATED MOVING AVERAGE) PADA PT MANDIRI JOGJA INTERNASIONAL*. 2. Retrieved from <https://ejurnal.kampusakademik.co.id/index.php/jmia/article/view/7312/6323>
- Sunendar, N., & Rianto, Y. (2025). COMPARISON OF ARIMA, LSTM, AND GRU MODELS FOR FORECASTING SALES OF HIT AEROSOL PRODUCTS. *Jurnal Pilar Nusa Mandiri*, 21(2), 153–159. <https://doi.org/10.33480/pilar.v21i2.6412>
- Suryawan, I. G. T., Putra, I. K. N., Meliana, P. M., & Sudipa, I. G. I. (2024). Performance Comparison of ARIMA, LSTM, and Prophet Methods in Sales Forecasting. *Sinkron*, 8(4), 2410–2421. <https://doi.org/10.33395/sinkron.v8i4.14057>
- Suseno, S. & Suryo Wibowo. (2023). Penerapan Metode ARIMA dan SARIMA Pada Peramalan Penjualan Telur Ayam Pada PT Agromix Lestari Group. *Jurnal Teknologi Dan Manajemen Industri Terapan*, 2(1), 33–40. <https://doi.org/10.55826/tmit.v2i1.85>
- Syahanifadhel, M. V., Basuki, D. E., Hasna, B. A., & Azzam, A. (2023). Analisis Perencanaan Produksi Pada Produk Kemeja Pola Menggunakan Metode Forecasting Dan Master Production Schedule Untuk Penjadwalan Produksi Pada CV. Jodion Unggul Perkasa. *Jurnal Teknik Industri: Jurnal Hasil Penelitian dan Karya Ilmiah dalam Bidang Teknik Industri*, 9(1), 95. <https://doi.org/10.24014/jti.v9i1.21890>
- Syamsi, A., Irfan, D., Novaliendry, D., & Sandra, R. P. (2026). Web-Based Inventory Management System for Educational Training: Integrating EOQ and ARIMA for Data-Driven Learning. *Journal of Hypermedia & Technology-Enhanced Learning*, 4(1), 68–87. <https://doi.org/10.58536/j-hytel.218>
- 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>
- Zhao, Y. (2024). Research on E-Commerce Retail Demand Forecasting Based on SARIMA Model and K-means Clustering Algorithm. *Academic Journal of Science and Technology*, 10(3), 226–231. <https://doi.org/10.54097/45acxz19>