

Artikel Penelitian

Perbandingan Metode Holt-Winters dan SARIMA untuk Memprediksi Permintaan Produk *Fashion* pada PT XYZ

Fauzan Firdaus, Mumu Komaro*, Vina Dwiyanti

Fakultas Pendidikan Teknik dan Industri, Teknik Logistik, Universitas Pendidikan Indonesia, Bandung, Indonesia

INFORMASI ARTIKEL

Diterima Redaksi: 30 November 2025

Revisi Akhir: 06 Januari 2026

Diterbitkan Online: 12 Januari 2026

KATA KUNCI

Holt-Winters

Overstock

Prediksi Permintaan

Produk *Fashion*

SARIMA

KORESPONDENSI (*)

Phone: +62 812-2002-2002

E-mail: mumu@upi.edu

A B S T R A K

Permintaan produk *fashion* yang bersifat musiman dan dipengaruhi oleh tren sering menimbulkan ketidaksesuaian antara jumlah produksi dan penjualan. Kondisi tersebut terjadi di PT XYZ khususnya pada produk *casual jeans*, di mana volume produksi secara konsisten melebihi penjualan dan terus meningkat setiap tahun. Ketidakseimbangan tersebut menunjukkan perlunya sistem peramalan yang mampu menggambarkan pola permintaan secara lebih akurat untuk mendukung perencanaan produksi dan pengendalian persediaan. Penelitian ini menggunakan metode kuantitatif dengan pendekatan komparatif untuk membandingkan performa metode Holt-Winters dan *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dalam memprediksi permintaan produk *casual jeans*. Penelitian ini menggunakan data sekunder penjualan bulanan dari Januari 2022 hingga Desember 2024 yang dianalisis menggunakan perangkat lunak RStudio. Akurasi kedua model diukur menggunakan *Mean Absolute Scaled Error* (MASE) dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa metode Holt-Winters *Additive* menghasilkan nilai MASE sebesar 0,399 dan MAPE 2,97%, sedangkan metode Holt-Winters *Multiplicative* memiliki nilai MASE 0,228 dan MAPE 1,55%. Sementara itu, model SARIMA (0,1,1) (1,1,0) [12] menunjukkan kinerja terbaik dengan nilai MASE 0,216 dan MAPE 1,43%, yang merupakan tingkat kesalahan terendah dibandingkan metode lainnya. Dengan demikian, metode SARIMA lebih sesuai digunakan untuk memprediksi permintaan produk *casual jeans* dengan pola musiman, serta dapat menjadi dasar dalam pengambilan keputusan produksi yang lebih efisien di PT XYZ.

PENDAHULUAN

Industri manufaktur merupakan sektor strategis yang berkontribusi signifikan terhadap pertumbuhan ekonomi nasional. Berdasarkan data Badan Pusat Statistik, sektor ini menyumbang 17,18 persen terhadap Produk Domestik Bruto (PDB) pada tahun 2024, meningkat dari 16,70 persen pada triwulan sebelumnya [1]. Salah satu subsektor yang paling dinamis adalah industri pakaian, yang sangat dipengaruhi oleh perubahan tren *fashion* dan preferensi konsumen [2]. Pergeseran preferensi tersebut mendorong perusahaan untuk terus berinovasi dalam desain, mempercepat proses produksi, dan menyesuaikan strategi pemasaran [3]. Fenomena *fast fashion* telah memperpendek siklus hidup produk, sehingga perusahaan dituntut mampu menyesuaikan produksi dengan cepat terhadap perubahan permintaan pasar [4]. Kondisi ini tidak hanya memengaruhi pola produksi, tetapi juga berdampak langsung pada dinamika permintaan dan ketersediaan produk [5].

Perubahan tren *fashion* yang berkembang cepat tersebut mendorong transformasi signifikan dalam pola pembelian dan preferensi konsumen [6]. Ketidakpastian permintaan akibat cepatnya pergantian tren memberikan dampak langsung pada penjualan, sehingga produsen harus mampu beradaptasi secara berkelanjutan [7]. Semakin tinggi permintaan konsumen, semakin besar peluang bagi perusahaan untuk meningkatkan penjualan dan keuntungan [8]. Namun, siklus produk yang cepat dan perubahan preferensi juga memengaruhi ketersediaan stok, menuntut perusahaan untuk menyesuaikan kapasitas

produksi dengan cermat [9]. Ketidakmampuan dalam menyesuaikan stok dengan permintaan berisiko menimbulkan kerugian finansial, menurunkan citra merek, dan mengurangi kepercayaan pelanggan [10].

PT XYZ merupakan perusahaan manufaktur garmen yang berpusat di Bandung dan memproduksi berbagai kategori pakaian seperti kaos, kemeja, jaket, dan celana untuk pasar domestik maupun internasional. Dari berbagai produk tersebut, segmen pakaian kasual menjadi fokus utama karena memiliki pangsa pasar luas dan dinamis. Salah satu produk andalannya adalah *casual jeans*, yang bersifat fleksibel, nyaman dan sesuai dengan tren mode kasual. Permintaan produk ini meningkat pada periode musiman, seperti menjelang hari raya dan akhir tahun [11]. Namun, PT XYZ menghadapi tantangan menyeimbangkan kapasitas produksi dengan fluktuasi permintaan. Selama periode 2022–2024, produksi selalu melebihi penjualan, dengan selisih 15.650 pcs pada 2022, 21.290 pcs pada 2023, dan 27.101 pcs pada 2024, sehingga menyebabkan *overstock* dan penumpukan produk di gudang. Akibatnya, PT XYZ mengalami kerugian kumulatif Rp 3,2 miliar dalam tiga tahun terakhir akibat biaya produksi yang tidak terserap, biaya penyimpanan, dan penurunan margin penjualan.

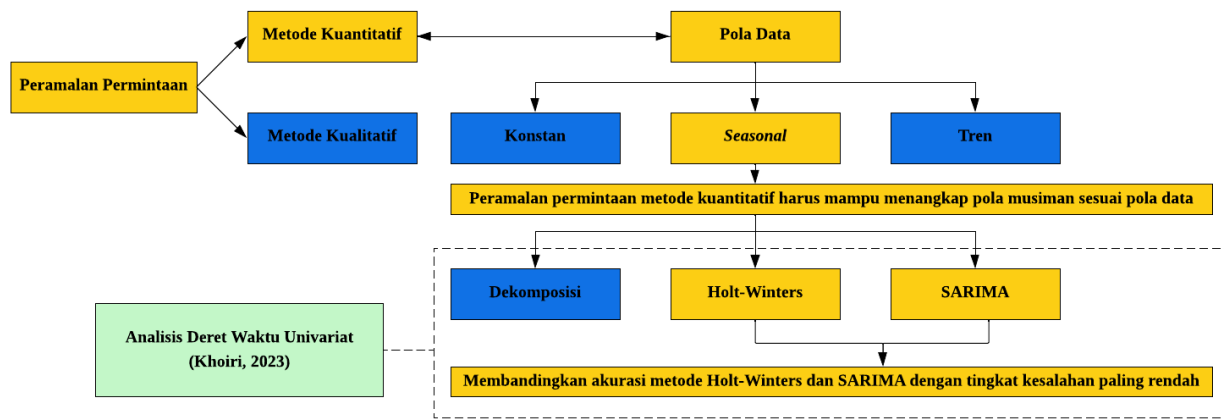
Ketidakseimbangan antara produksi dan penjualan menegaskan pentingnya penerapan sistem peramalan permintaan yang akurat untuk mendukung pengambilan keputusan produksi dan pengendalian persediaan [12]. Peramalan permintaan membantu perusahaan menyesuaikan kapasitas produksi dengan kebutuhan pasar dan menekan risiko *overstock* maupun *stockout* [13]. Dalam industri pakaian yang sangat dipengaruhi oleh dinamika *tren fashion*, kemampuan memprediksi perubahan permintaan secara akurat menjadi kunci keberhasilan dalam menjaga efisiensi operasional dan stabilitas keuntungan [14]. Namun, berdasarkan hasil wawancara dengan kepala produksi PT XYZ, proses peramalan masih dilakukan secara sederhana, yaitu mengandalkan perkiraan bulanan berdasarkan data historis tahun sebelumnya tanpa dukungan model statistik yang sistematis. Pendekatan peramalan tersebut memiliki keterbatasan dalam menangkap dinamika dan variasi permintaan, sehingga tingkat akurasi relatif rendah akibat minimnya analisis kuantitatif. Kondisi ini menyebabkan hasil peramalan sering tidak mencerminkan pola permintaan aktual dan berdampak pada kesalahan dalam penentuan jumlah produksi [15].

Ketidaktepatan dalam peramalan permintaan di PT XYZ menunjukkan perlunya penerapan metode yang sistematis dan selaras dengan karakteristik produk yang bersifat musiman. Berdasarkan kebutuhan tersebut, salah satu metode yang banyak digunakan dalam peramalan deret waktu adalah Holt-Winters karena mampu menangkap komponen level, tren, dan musiman secara simultan, sehingga sangat sesuai untuk data penjualan yang memiliki pola stabil [16]. Selain Holt-Winters, metode lain yang relevan adalah *Seasonal Autoregressive Integrated Moving Average* (SARIMA), yang efektif untuk menangkap fluktuasi musiman yang kompleks dan pola berulang secara periodik [17]. Namun, penelitian yang membandingkan secara langsung akurasi kedua metode tersebut untuk produk *casual jeans* di industri pakaian masih sangat terbatas, sehingga efektivitasnya dalam konteks ini belum diketahui.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan membandingkan akurasi metode Holt-Winters dan SARIMA dalam memprediksi permintaan produk *casual jeans* di PT XYZ, sehingga dapat diperoleh metode dengan tingkat kesalahan paling rendah untuk mendukung pengambilan keputusan produksi secara lebih efektif. Implementasi kedua metode dilakukan menggunakan perangkat lunak RStudio yang mendukung proses perhitungan dan visualisasi hasil prediksi secara efisien. Hasil penelitian diharapkan memberikan kontribusi praktis bagi PT XYZ dalam mengoptimalkan perencanaan produksi, pengendalian persediaan, dan pengambilan keputusan, sekaligus memperkaya literatur mengenai penerapan metode peramalan musiman di industri pakaian.

TINJAUAN PUSTAKA

Kerangka teori penelitian ini disusun sebagai acuan konseptual yang menjelaskan keterkaitan antara teori peramalan permintaan, pola data deret waktu, dan pemilihan metode peramalan, sebagaimana disajikan pada Gambar 1.



Gambar 1. Kerangka Teori

Berdasarkan kerangka teori pada Gambar 1, penelitian ini berlandaskan pada teori peramalan permintaan yang mengklasifikasikan pendekatan peramalan ke dalam metode kualitatif dan kuantitatif. Penelitian ini menggunakan pendekatan kuantitatif dengan menganalisis data historis permintaan sebagai data deret waktu (*time series*). Secara teoretis, data deret waktu memiliki karakteristik pola tertentu yang dapat berupa pola konstan, tren dan *seasonal* [18]. Berdasarkan karakteristik tersebut, penelitian ini difokuskan pada pola musiman dengan menerapkan metode Holt-Winters dan SARIMA untuk memperoleh tingkat akurasi peramalan terbaik berdasarkan nilai kesalahan terkecil.

Peramalan Permintaan

Peramalan permintaan merupakan suatu teknik yang digunakan untuk memperkirakan jumlah kebutuhan di masa mendatang berdasarkan data historis dan kondisi saat ini [19]. Secara umum, metode peramalan dibedakan menjadi dua kategori, yaitu metode kualitatif dan metode kuantitatif. Metode kualitatif lebih menekankan pada intuisi, pengalaman, serta pendapat pakar dalam memperkirakan permintaan, sedangkan metode kuantitatif menggunakan pendekatan matematis dan statistika untuk menghasilkan prediksi yang lebih objektif dan terukur [20]. Ketepatan hasil peramalan sangat bergantung pada sejauh mana metode yang digunakan mampu meminimalkan perbedaan antara hasil estimasi dan data aktual [21]. Salah satu pendekatan kuantitatif yang banyak digunakan dalam peramalan permintaan adalah analisis deret waktu (*time series analysis*) [22]. Melalui analisis deret waktu, peneliti dapat mengenali pola dasar yang muncul dalam data, seperti pola konstan, tren dan musiman. Pola konstan menunjukkan stabilitas nilai di sekitar rata-rata, sedangkan pola tren menandakan adanya kecenderungan naik atau turun secara bertahap. Sementara itu, pola musiman menggambarkan fluktuasi yang berulang pada periode tertentu [23].

Program R

Program R merupakan bahasa pemrograman sekaligus lingkungan komputasi statistik berbasis *open-source* yang banyak digunakan dalam analisis data, pemodelan statistik, serta visualisasi, karena memiliki fleksibilitas tinggi dan dukungan berbagai *package* untuk kebutuhan analisis [24]. Dalam penerapannya, R umumnya dijalankan melalui RStudio, yaitu sebuah *Integrated Development Environment* (IDE) yang menyediakan antarmuka interaktif untuk mempermudah pengembangan kode, pengolahan data, serta penyajian hasil analisis secara sistematis dan terstruktur [25]. Tahapan awal dalam analisis peramalan permintaan meliputi proses instalasi serta pemanggilan *package* yang relevan dengan metode yang digunakan. Adapun *package* utama yang digunakan dalam penelitian ini ditampilkan pada Tabel 1 berikut:

Tabel 1. *Package* R yang Digunakan dalam Analisis Peramalan Permintaan

Nama <i>Package</i>	Keterangan Penggunaan
readxl	Digunakan untuk membaca file Excel (.xlsx) sehingga data permintaan dapat diimpor ke R [26].
zoo	Memanipulasi data deret waktu yang tidak teratur sebelum dikonversi menjadi <i>time series</i> [27].
forecast	Membuat model peramalan dan prediksi jumlah permintaan, baik menggunakan Holt-Winters dan SARIMA [28].
tseries	Melakukan uji statistik seperti ADF test untuk mengetahui stasioneritas data sebelum pemodelan [29].

Nama Package	Keterangan Penggunaan
ggplot2	Menampilkan tren, pola musiman, dan fluktuasi data melalui visualisasi berbasis <i>Grammar of Graphics</i> [30].
MASS	Mendukung pengujian model dan estimasi parameter [31].
lmtest	Menyediakan alat evaluasi asumsi model statistik, seperti autokorelasi dan heteroskedastisitas [32].

Setelah instalasi, *package* dipanggil menggunakan `library()`, sehingga seluruh fungsi dapat langsung digunakan untuk eksplorasi data dan pemodelan peramalan [33]. Data permintaan dalam format `.csv` atau `.xlsx` dibaca menggunakan `read_excel()` dan dikonversi menjadi objek *time series* agar fungsi peramalan di R dapat mengenali pola tren dan musiman dengan tepat, dengan periode awal dan frekuensi data sesuai kebutuhan. Selanjutnya visualisasi sederhana menggunakan `plot()` memberikan gambaran umum pola permintaan, sementara `ggplot2` menampilkan tren dan fluktuasi bulanan secara lebih jelas, memudahkan peneliti dalam menentukan metode peramalan yang tepat [34].

Metode Holt-Winters

Metode Holt-Winters atau *Triple Exponential Smoothing* (TES), merupakan pengembangan dari Metode *Exponential Smoothing*, yaitu teknik peramalan deret waktu (*time series*) yang memberikan bobot lebih besar pada data terbaru agar ramalan lebih responsif terhadap perubahan pola data [35]. Holt-Winters dirancang khusus untuk menganalisis data yang memiliki tren dan pola musiman secara bersamaan dengan tiga parameter pemulusan utama, yaitu α (α) untuk level, β (β) untuk tren, dan γ (γ) untuk musiman [36]. Penelitian oleh Sarasi et al. [37] pada penjualan *scarf* muslimah menunjukkan bahwa Holt-Winters mampu menghasilkan peramalan dengan tingkat akurasi sangat tinggi. Selain itu, penelitian oleh Kačmárý et al. [38] menegaskan bahwa Holt-Winters efektif untuk industri tekstil dan pakaian karena mampu menangkap pola musiman yang kuat. Metode ini memiliki dua pendekatan, yaitu model *Additive* dan *Multiplicative* sebagai berikut:

1. Holt-Winters *Additive*

Metode Holt-Winters *Additive* digunakan untuk menganalisis data deret waktu (*time series*) yang memiliki pola tren dan musiman dengan fluktuasi yang relatif konstan [39]. Pendekatan ini cocok untuk data di mana perubahan musiman memiliki pengaruh yang sama setiap periode, seperti pola penjualan yang berulang secara stabil dari tahun ke tahun [40]. Dalam praktik analisis menggunakan RStudio, model ini dapat diterapkan dengan input sebagai berikut:

```
hw.add = hw(Datapermintaanperusahaan.ts,
h = 12,
seasonal = "additive",
alpha = NULL, beta = NULL, gamma = NULL)
print(hw.add$model)
```

(1)

Berdasarkan input 1 model Holt-Winters *Additive* diterapkan menggunakan fungsi `hw()` dari *package* `forecast`. Fungsi `hw.add = hw(Datapermintaanperusahaan.ts, h = 12, seasonal = "additive", alpha = NULL, beta = NULL, gamma = NULL)` digunakan untuk membuat prediksi 12 periode ke depan berdasarkan data permintaan perusahaan. Parameter `seasonal = "additive"` menunjukkan model yang dipilih untuk peramalan, sedangkan `alpha`, `beta`, dan `gamma = NULL` memungkinkan RStudio secara otomatis menentukan parameter pemulusan yang optimal berdasarkan pola data. Fungsi `hw.add` yang dihasilkan menyimpan seluruh informasi model, termasuk komponen level, tren, dan musiman, dan peneliti dapat menampilkan parameter tersebut menggunakan `hw.add$model` untuk memeriksa nilai yang digunakan dalam peramalan [41].

2. Holt-Winters *Multiplicative*

Metode Holt-Winters *Multiplicative* digunakan untuk menganalisis data deret waktu yang memiliki tren dan variasi musiman yang berubah secara proporsional terhadap level data [42]. Artinya, semakin besar nilai data, maka fluktuasi musiman juga semakin besar. Model ini sesuai digunakan untuk data ekonomi, keuangan, atau penjualan yang mengalami peningkatan tren dengan pola musiman yang ikut membesar [43]. Dalam praktik analisis menggunakan RStudio, model ini dapat diterapkan dengan fungsi sebagai berikut:

```
Holt-Winters Multiplicative
hw.multi = hw(Datapermintaanperusahaan.ts,
h = 12,
seasonal = "multiplicative",
alpha = NULL, beta = NULL, gamma = NULL)
print(hw.mul$model)
```

(2)

Berdasarkan input 2 model Holt-Winters *Multiplicative* diterapkan menggunakan fungsi `hw()` dari *package forecast*. Sebagai contoh, `hw.mul= hw(Datapermintaanperusahaan.ts, h = 12, seasonal = "multiplicative", alpha = NULL, beta = NULL, gamma = NULL)` digunakan untuk membuat prediksi 12 periode ke depan berdasarkan data permintaan perusahaan. Parameter `seasonal = "multiplicative"` menunjukkan model yang dipilih untuk peramalan, sedangkan `alpha`, `beta`, dan `gamma = NULL` memungkinkan RStudio secara otomatis menentukan parameter pemulusan yang optimal berdasarkan pola data [44]. Objek `hw.multi` yang dihasilkan menyimpan seluruh informasi model, termasuk komponen level, tren, dan musiman, dan peneliti dapat menampilkan parameter tersebut menggunakan `hw.multi$model` untuk memeriksa nilai yang digunakan dalam peramalan.

Metode Seasonal Autoregressive Integrated Moving Average (SARIMA)

Metode SARIMA (*Seasonal Autoregressive Integrated Moving Average*) digunakan untuk menganalisis dan meramalkan data deret waktu (*time series*) yang mampu menangkap pola musiman yang berulang secara periodik sekaligus fluktuasi acak, sehingga sangat sesuai untuk prediksi permintaan bulanan atau tahunan [45]. Pada produk *fashion*, di mana permintaan sering dipengaruhi oleh tren yang berubah-ubah, penelitian oleh Negre et al. [46] menunjukkan bahwa SARIMA mampu memprediksi penjualan produk *fashion footwear* dengan tingkat akurasi tinggi. Lebih lanjut, kemampuan SARIMA menangkap pola berulang membuatnya relevan untuk memodelkan dan meramalkan tren umum produk pakaian dari data ketertarikan publik (*Google Trends*) [47]. Metode ini merupakan pengembangan dari ARIMA, yang pada dasarnya menggabungkan tiga komponen yaitu *autoregressive* (AR), *moving average* (MA), dan integrasi (*I/differencing*). Model AR mengasumsikan bahwa nilai saat ini dipengaruhi oleh nilai-nilai sebelumnya dari variabel yang sama, sedangkan model MA menangkap pengaruh residual atau guncangan acak dari periode sebelumnya. Kombinasi keduanya membentuk ARMA, yang efektif untuk memprediksi data stasioner. SARIMA memperluas ARIMA dengan menambahkan komponen musiman, yaitu *P* (*autoregressive* musiman), *D* (*differencing* musiman), *Q* (*moving average* musiman), dan *s* sebagai periode musiman [48]. Notasi lengkap model ini dinyatakan sebagai:

$$\text{ARIMA}(p, d, q)(P, D, Q)^s \quad (3)$$

dengan,

(p, d, q) = bagian tidak musiman dari model

(P, D, Q) = bagian musiman dari model

P = orde musiman AR

D = banyaknya musiman yang di differencing

Q = orde musiman MA

S = jumlah periode per musim

Dalam praktik analisis menggunakan RStudio, metode SARIMA dapat diterapkan melalui beberapa tahap sebagai berikut:

1. Uji Stasioneritas

Stasioneritas menunjukkan bahwa data tidak mengalami perubahan signifikan dari waktu ke waktu. Fluktuasi data berada di sekitar nilai rata-rata yang konstan dan variansnya. Kondisi ini penting karena model SARIMA mensyaratkan data stasioner agar estimasi parameter menjadi valid dan prediksi akurat [49]. Jika data tidak stasioner, prediksi menggunakan model SARIMA bisa menjadi bias karena pola tren atau musiman yang tidak stabil akan mempengaruhi parameter model dan hasil peramalan. Salah satu metode yang paling umum digunakan untuk menguji stasioneritas adalah Augmented Dickey-Fuller (ADF). Uji ADF menambahkan nilai dari periode sebelumnya, yang disebut *lag*, untuk mengurangi pengaruh hubungan antarnilai sebelumnya (autokorelasi) pada sisa (residual), sehingga hasil uji menjadi lebih akurat [50]. Hipotesis nol (H_0) pada ADF menyatakan bahwa data tidak stasioner, sedangkan hipotesis alternatif (H_1) menyatakan bahwa data stasioner [51]. Dalam praktik RStudio, uji ADF dapat dilakukan menggunakan fungsi `adf.test()` dari *package tseries* dengan input sebagai berikut:

```
adf_test <- adf.test(Datapermintaanperusahaan.ts)
print(adf_test) (4)
```

Hasil uji menampilkan *p-value*. Ketentuan yang umum digunakan adalah:

- Jika *p-value* < 0,05 → Tolak H_0 → Data stasioner.
- Jika *p-value* ≥ 0,05 → Gagal menolak H_0 → Data belum stasioner dan perlu diferensiasi.

Jika data belum stasioner, langkah selanjutnya adalah melakukan *differencing* untuk membuat data memenuhi asumsi stasioneritas sebelum diterapkan ke model SARIMA [52].

2. Differencing

Differencing merupakan proses penting untuk menghilangkan tren atau fluktuasi yang membuat data tidak stasioner, sehingga rata-rata data menjadi konstan [53]. *Differencing* dapat dilakukan pada dua level, yaitu non-musiman dan musiman, serta kombinasi sebagai berikut:

- *Differencing* Non-Musiman (d)

Differencing non-musiman digunakan untuk menstabilkan rata-rata data dengan menghilangkan tren linear atau non-stasioner. Implementasi pada RStudio dapat dilakukan dengan input berikut:

```
diff1 <- diff(Datapermintaanperusahaan.ts, differences = 1) (5)
```

Parameter `differences = 1` menunjukkan ($d = 1$), artinya data dikurangi dengan nilai periode sebelumnya sebanyak satu kali. Apabila ADF test menunjukkan *p-value* < 0,05, data dianggap telah stasioner [54].

- *Differencing* Musiman (D)

Differencing musiman bertujuan untuk menetralkan fluktuasi musiman yang berulang secara periodik, misalnya pola penjualan bulanan. Implementasi pada RStudio dapat dilakukan dengan input berikut:

```
diff_seasonal <- diff(Datapermintaanperusahaan.ts, lag = 12) (6)
```

Parameter `lag = 12` menunjukkan ($D = 1$) untuk satu kali *differencing* musiman, dengan 12 sebagai jumlah periode per musim pada data bulanan [55].

- *Differencing* Kombinasi (d) dan (D)

Jika data memiliki tren jangka panjang sekaligus pola musiman, *differencing* non-musiman dan musiman dilakukan secara berurutan. Implementasi pada RStudio dapat dilakukan dengan input berikut:

```
diff_combined <- diff(diff(Datapermintaanperusahaan.ts), lag = 12) (7)
```

Pendekatan kombinasi ini memastikan data stasioner baik pada rata-rata maupun pola musiman, sehingga identifikasi parameter SARIMA (p, d, q, P, D, Q) dapat dilakukan dengan valid dan prediksi menjadi lebih akurat [56].

3. Identifikasi Parameter Model (ACF dan PACF)

Setelah data menjadi stasioner melalui *differencing*, tahap berikutnya adalah identifikasi parameter menggunakan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). ACF mengukur korelasi pada *lag* tertentu untuk menentukan orde *Moving Average* (MA, q) dan MA musiman (Q), sedangkan PACF mengukur korelasi setelah efek *lag* perantara dihilangkan untuk menentukan orde *Autoregressive* (AR, p) dan AR musiman (P) [57]. Dalam praktik di RStudio, analisis ACF dan PACF dapat dilakukan dengan input berikut:

```
par(mfrow = c(1,2))
acf(diff_combined, main = "ACF Setelah Differencing") (8)
pacf(diff_combined, main = "PACF Setelah Differencing")
```

Berdasarkan input 8 `diff_combined` merupakan data yang telah stasioner baik secara non-musiman maupun musiman. Pola potongan signifikan pada grafik ACF dan PACF digunakan untuk memperkirakan parameter $p, q, P,$ dan Q . Di mana *cutoff* pada ACF membantu menentukan nilai q atau Q , sedangkan *cutoff* pada PACF membantu menentukan nilai p atau P [58].

4. Pemodelan SARIMA

Pemodelan SARIMA bertujuan untuk menentukan kombinasi parameter terbaik (p, d, q, P, D, Q, s) yang mampu menangkap pola musiman, tren, dan fluktuasi acak dalam deret waktu. Dalam praktik analisis di RStudio, proses ini dapat dilakukan secara manual berdasarkan hasil identifikasi ACF dan PACF, atau secara otomatis menggunakan fungsi `auto.arima()` dari *package forecast* [59]. Implementasi di RStudio dapat dilakukan dengan input berikut:

```
model_sarima <- auto.arima(Datapermintaanperusahaan.ts,
                           seasonal = TRUE,
                           stepwise = FALSE,
                           approximation = FALSE)
summary(model_sarima)
```

(9)

Berdasarkan input 9 fungsi `auto.arima()` akan menyeleksi model terbaik dengan membandingkan berbagai kombinasi parameter (p, d, q, P, D, Q) menggunakan kriteria seperti *Akaike Information Criterion* (AIC). Model dengan nilai AIC terkecil dianggap paling optimal karena menunjukkan keseimbangan terbaik antara kompleksitas model dan kemampuan menjelaskan variasi data [60]. Selain itu, hasil keluaran fungsi `summary(model_sarima)` menampilkan estimasi parameter, nilai standar *error*, serta statistik diagnostik model. Informasi ini penting untuk menilai apakah setiap parameter signifikan dan apakah struktur model telah sesuai dengan pola data.

5. Hasil Peramalan

Hasil peramalan yaitu memproyeksikan nilai permintaan di masa depan berdasarkan model yang telah dibangun. Dalam praktik analisis di RStudio, peramalan dilakukan menggunakan fungsi `forecast()` dari *package forecast*, yang memanfaatkan model SARIMA yang telah dipasang sebagai berikut:

```
forecast_sarima <- forecast(model_sarima, h = 12)
print(forecast_sarima)
autoplot(forecast_sarima) +
  labs(title = "Forecast Permintaan Perusahaan 12 Bulan ke Depan",
        x = "Tahun",
        y = "Jumlah Permintaan") +
  theme_minimal()
```

(10)

Berdasarkan input 10 argumen $h = 12$ menunjukkan bahwa prediksi dilakukan untuk 12 periode ke depan, misalnya 12 bulan. Fungsi `forecast_sarima` menyimpan nilai prediksi, sehingga peneliti dapat melihat rentang kemungkinan nilai permintaan dan mengantisipasi fluktuasi yang mungkin terjadi. Visualisasi hasil peramalan dengan `autoplot()` memudahkan interpretasi pola tren dan musiman, serta memberikan gambaran yang lebih jelas tentang proyeksi permintaan di masa depan [61].

6. Uji Kelayakan Model (*Residual Analysis*)

Uji kelayakan model melalui analisis residual bertujuan untuk mengetahui selisih antara nilai aktual dengan nilai yang diprediksi oleh model [62]. Residual yang ideal bersifat acak (*white noise*), tidak memiliki autokorelasi, dan terdistribusi secara normal. Analisis ini membantu memastikan bahwa model SARIMA valid dan dapat digunakan untuk prediksi yang akurat [63]. Dalam praktik analisis di RStudio, uji kelayakan residual dilakukan melalui beberapa tahap, yaitu:

- Uji *Coefficient Significance*

Uji *coefstest* digunakan untuk memeriksa signifikansi parameter dalam model SARIMA. Jika nilai *p-value* $< 0,05$, maka parameter tersebut signifikan dan berkontribusi dalam menjelaskan variasi data [64]. Implementasi di RStudio dapat dilakukan dengan input berikut:

```
coefstest(model_sarima)
```

(11)

- Uji Normalitas Residual

Uji *Kolmogorov-Smirnov* digunakan untuk memeriksa apakah distribusi residual mendekati distribusi normal. Jika *p-value* $> 0,05$, maka asumsi normalitas terpenuhi [65]. Implementasi di RStudio dapat dilakukan dengan input berikut:

```
ks.test(residuals(model_sarima), "pnorm", mean(residuals
(model_sarima)), sd(residuals(model_sarima)))
```

 (12)

- Uji Autokorelasi Residual
Uji Ljung-Box `Box.test()` digunakan untuk memeriksa independensi residual. Jika $p\text{-value} > 0,05$, residual dianggap independen dan model valid [66]. Implementasi di RStudio dapat dilakukan dengan input berikut:

```
Box.test(residuals(model_sarima), lag = 12, type = "Ljung-Box")
```

 (13)

Hasil dari ketiga tahap ini memberikan gambaran apakah model SARIMA telah menangkap struktur tren dan musiman pada data dengan baik. Residual yang acak, normal, dan independen menandakan bahwa model valid dan siap digunakan [67].

Uji Verifikasi

Prediksi hasil peramalan tidak selalu sesuai dengan kondisi nyata di lapangan. Ketidaksesuaian tersebut disebut sebagai *forecast error*, yaitu selisih antara nilai hasil prediksi dengan data aktual [68]. Tingkat keakuratan suatu model peramalan dapat diketahui dengan menganalisis besarnya perbedaan antara data hasil ramalan dan data sebenarnya, sehingga dapat dinilai sejauh mana model tersebut mampu menggambarkan pola yang sesungguhnya [69]. Beberapa metrik yang digunakan dalam uji verifikasi model deret waktu adalah:

1. *Mean Absolute Scaled Error* (MASE)

MASE adalah metrik yang membandingkan kesalahan absolut model terhadap kesalahan absolut metode naive sederhana, sehingga memberikan ukuran akurasi yang tidak terpengaruh skala data dan memungkinkan perbandingan antar model atau dataset berbeda. Nilai $MASE < 1$ menunjukkan bahwa model lebih baik dibandingkan metode naive, sedangkan $MASE > 1$ menandakan model kurang akurat [70].

2. *Mean Percentage Error* (MAPE)

MAPE merupakan ukuran kesalahan relatif yang menyatakan persentase kesalahan hasil peramalan terhadap permintaan aktual selama periode tertentu yang akan memberikan informasi persentase kesalahan terlalu tinggi atau terlalu rendah dimana nilai $MAPE < 10\%$ menandakan kemampuan model peramalan sangat baik [71].

Dalam praktik analisis di RStudio, evaluasi kesalahan untuk metode Holt-Winters dan SARIMA dapat dilakukan menggunakan fungsi `accuracy()` dari *package forecast*. Implementasinya adalah sebagai berikut:

```
accuracy(hw.add)
accuracy(hw.multi)
accuracy(forecast_sarima)
```

 (14)

Berdasarkan input 14 fungsi `accuracy()` menghasilkan nilai MASE dan MAPE dari masing-masing model, sehingga peneliti dapat langsung membandingkan performa model. Model dengan nilai MASE dan MAPE terkecil menunjukkan prediksi paling akurat dengan tingkat keandalan tinggi [72].

Uji Validasi (Moving Range)

Peta *Moving Range* berfungsi sebagai alat analisis untuk membandingkan nilai permintaan aktual dengan hasil peramalan yang diperoleh pada periode yang sama [73]. Penerapan peta ini dilakukan untuk memantau kestabilan hasil peramalan dari waktu ke waktu [74]. Dalam praktik RStudio, *Moving Range* dapat dihitung dan divisualisasikan menggunakan residual dari model sebagai berikut:

```
residual <- residuals(model_sarima)
MR <- abs(diff(residual_sarima))
X_bar <- mean(res, na.rm = TRUE)
MR_bar <- mean(moving_range, na.rm = TRUE)
UCL <- X_bar + 2.66 * MR_bar
LCL <- X_bar - 2.66 * MR_bar
```

 (15)

Berdasarkan input 15 fungsi `residuals(model)` digunakan untuk memperoleh selisih antara nilai aktual dan nilai hasil peramalan, menghasilkan vektor residual untuk setiap periode. Fungsi `diff()` menghitung perbedaan antar elemen residual secara berurutan, sedangkan `abs()` mengubah hasilnya menjadi nilai absolut agar hanya menggambarkan besar perubahan tanpa memperhatikan arah perubahannya. Nilai rata-rata residual (\bar{x}) dihitung untuk mendapatkan garis tengah (*center line*), sedangkan nilai rata-rata *Moving Range* (\bar{MR}) mencerminkan tingkat variasi rata-rata antar periode. Selanjutnya, batas kendali atas (UCL) dan batas kendali bawah (LCL) ditentukan menggunakan konstanta 2,66 sebagai acuan kestabilan proses [75].

METODOLOGI

Penelitian ini menggunakan metode kuantitatif dengan pendekatan komparatif untuk membandingkan performa metode Holt-Winters dan SARIMA dalam memprediksi permintaan produk *casual jeans* di PT XYZ. Metode kuantitatif digunakan karena penelitian ini mengandalkan data numerik, analisis statistik, serta pengujian terhadap fenomena yang diamati [76]. Pendekatan komparatif digunakan untuk mengetahui perbedaan efektivitas antara dua metode peramalan, di mana data dianalisis secara statistik untuk menentukan model yang memberikan hasil paling akurat [77]. Seluruh analisis peramalan dilakukan menggunakan RStudio versi 2025.09.2+418 dengan *package* R yang relevan untuk peramalan.

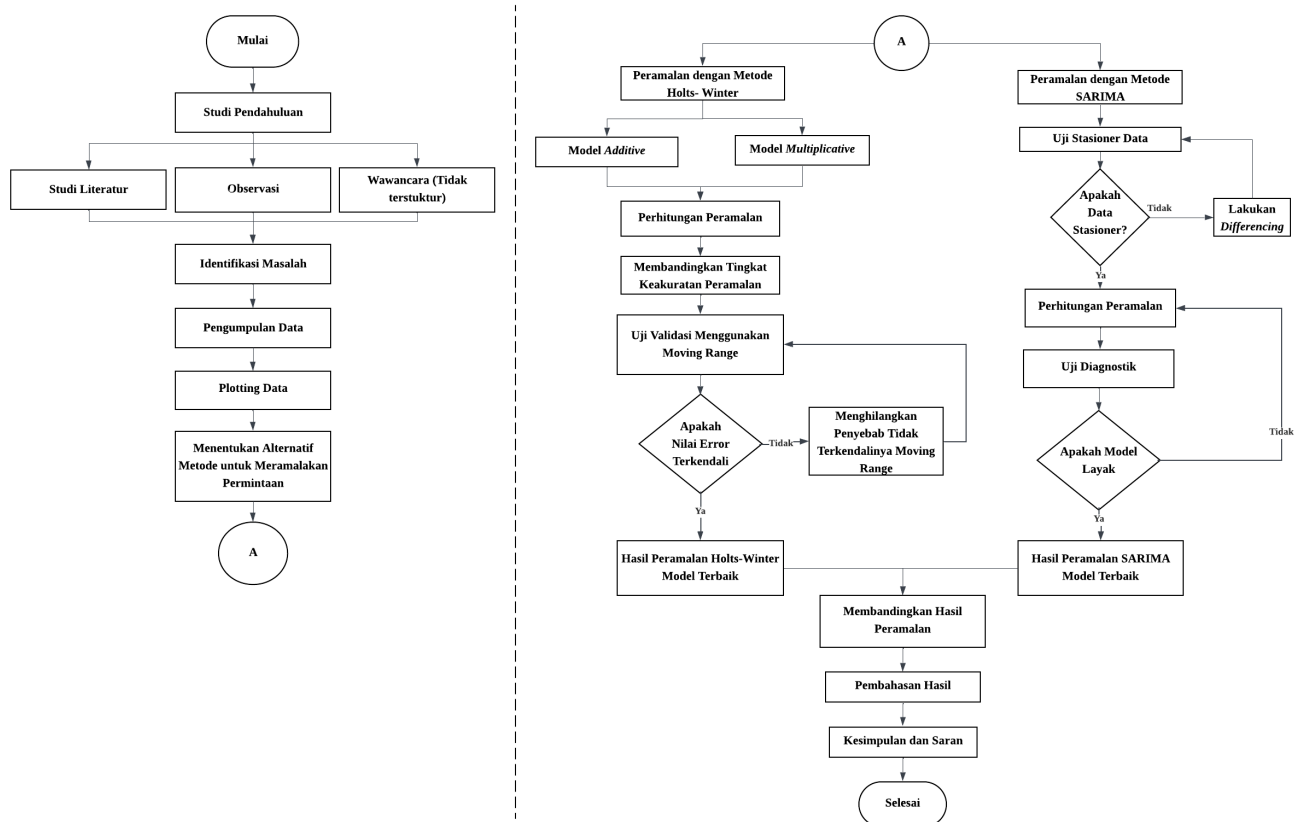
Dalam praktiknya, data historis penjualan produk *casual jeans* PT XYZ diimpor ke dalam R menggunakan *package readxl*, kemudian disusun menjadi data deret waktu bulanan dengan *package zoo* agar struktur data sesuai dengan karakteristik runtun waktu. Setelah data tersusun, eksplorasi awal dilakukan melalui visualisasi deret waktu menggunakan *package ggplot2* untuk mengidentifikasi pola tren, musiman, dan fluktuasi permintaan. Berdasarkan karakteristik data tersebut, proses pemodelan peramalan dilakukan dengan menerapkan metode Holt-Winters dan SARIMA menggunakan *package forecast*. Selanjutnya, pengujian kelayakan model didukung oleh *package tseries*, *lmtest*, dan *MASS*. Kriteria pemilihan model dilakukan berdasarkan tingkat akurasi hasil peramalan, di mana model dengan nilai MAPE dan MASE terkecil dipilih sebagai model terbaik.

Jenis Data

Penelitian ini menggunakan data sekunder, yaitu data yang telah dikumpulkan sebelumnya oleh perusahaan atau instansi terkait untuk tujuan tertentu [78]. Data yang digunakan berupa data historis penjualan produk *casual jeans* PT.XYZ periode Januari 2022–Desember 2024. Data tersebut dimanfaatkan secara keseluruhan dalam proses pemodelan dan peramalan tanpa pemisahan data latih dan data uji dengan evaluasi kinerja model dilakukan melalui perbandingan nilai *error* terkecil.

Alur Penelitian

Alur pada penelitian ditampilkan dalam bentuk *flowchart* pada Gambar 2.



Gambar 2. Alur Penelitian

Berdasarkan Gambar 1. langkah-langkah yang dilakukan peneliti sebagai berikut:

1. Studi Pendahuluan
Tahap awal dilakukan melalui studi literatur untuk mengidentifikasi konsep peramalan, pola deret waktu, serta penelitian sebelumnya. Selain itu dilakukan observasi proses pengelolaan persediaan di PT XYZ, serta wawancara tidak terstruktur untuk memperoleh gambaran masalah yang terjadi.
2. Identifikasi Masalah
Berdasarkan studi pendahuluan, ditemukan adanya ketidakseimbangan antara volume produksi dan penjualan yang mengakibatkan penumpukan persediaan (*overstock*). Kondisi ini menegaskan perlunya metode peramalan yang mampu menangkap pola musiman secara akurat.
3. Pengumpulan Data
Data historis penjualan *casual jeans* PT.XYZ periode Januari 2022–Desember 2024 dikumpulkan sebagai dasar analisis peramalan permintaan.
4. *Plotting* Data
Data yang terkumpul divisualisasikan untuk mengidentifikasi pola tren, musiman, dan fluktuasi yang muncul pada deret waktu.
5. Menentukan Alternatif untuk Meramalkan Permintaan
Berdasarkan karakteristik data yang menunjukkan pola musiman, dipilih metode Holt-Winters dan SARIMA sebagai metode yang dapat menangkap pola tersebut dan layak untuk dibandingkan performanya.
6. Peramalan dengan Metode Holt-Winters
Metode Holt-Winters diterapkan dalam dua model, yaitu model *Additive* dan *Multiplicative*. Seluruh proses perhitungan dilakukan menggunakan RStudio sesuai dengan input (1) dan (2). Penentuan parameter pemulusan level (α), tren (β) dan musiman (γ) dilakukan secara otomatis oleh perangkat lunak melalui mekanisme optimasi internal pada fungsi $hw()$, tanpa penetapan nilai awal secara manual. Parameter yang dihasilkan merupakan nilai yang meminimalkan *error* peramalan. Akurasi model dievaluasi menggunakan MAPE dan MASE sebagaimana tercantum pada input (14), sedangkan kestabilan model diuji menggunakan metode *moving range* berdasarkan input (15).

7. Peramalan dengan Metode SARIMA

Peramalan dengan metode SARIMA diimplementasikan sepenuhnya melalui RStudio. Tahapan analisis dimulai dengan uji stasioneritas sesuai input (4). Jika data belum stasioner, dilakukan proses *differencing* mengacu pada input (5), (6), dan (7). Selanjutnya dilakukan identifikasi parameter model berdasarkan input (8), penentuan model dilakukan secara otomatis menggunakan fungsi `auto.arima()` pada perangkat lunak Rstudio, yang mengevaluasi berbagai kombinasi orde non-musiman dan musiman berdasarkan kriteria informasi untuk memperoleh model dengan performa terbaik sesuai input (9), serta perhitungan peramalan sebagaimana pada input (10). Evaluasi kelayakan model dilakukan melalui diagnostik residual menggunakan Uji *Coefstest* (11), Uji Kolmogorov–Smirnov (12), dan Uji Ljung–Box (13). Apabila model tidak memenuhi kriteria diagnostik, dilakukan penyesuaian dan pengujian ulang hingga diperoleh model SARIMA yang paling optimal.

8. Membandingkan Hasil Peramalan

Hasil peramalan dari Holt-Winters dan SARIMA dibandingkan berdasarkan nilai *error* MASE dan MAPE. Model dengan nilai *error* paling kecil dipilih sebagai model dengan performa terbaik dalam memprediksi permintaan *casual jeans*.

9. Pembahasan Hasil

Pada tahap ini, peneliti menganalisis dan menginterpretasikan hasil peramalan dari kedua metode dengan membandingkannya terhadap data aktual. Evaluasi dilakukan berdasarkan nilai *error* dan kemampuan masing-masing model dalam mengikuti pola data historis.

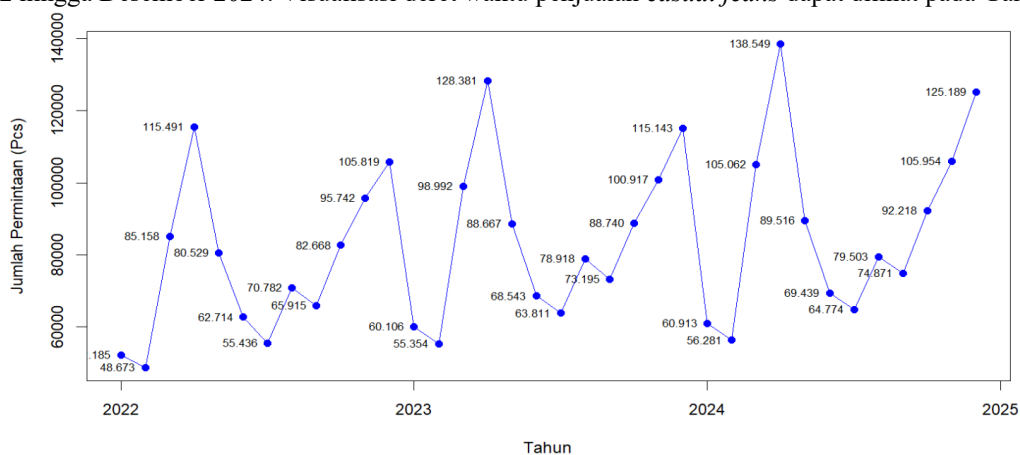
10. Kesimpulan dan Saran

Tahap akhir berisi penarikan kesimpulan mengenai metode peramalan yang paling efektif sesuai dengan karakteristik pola permintaan perusahaan. Peneliti juga memberikan saran yang dapat diterapkan perusahaan maupun rekomendasi untuk penelitian selanjutnya.

HASIL DAN PEMBAHASAN

Plotting Data

Dalam proses peramalan, langkah awal yang dilakukan adalah mengidentifikasi karakteristik pola data melalui *plotting* untuk memahami kecenderungan dan pola penjualan [79]. Pengolahan data dilakukan menggunakan RStudio, dimulai dari proses *load data*, kemudian dikonversi ke dalam format *time series* dengan frekuensi bulanan yang dimulai pada Januari 2022 hingga Desember 2024. Visualisasi deret waktu penjualan *casual jeans* dapat dilihat pada Gambar 3.



Gambar 3. Plot Data Penjualan *Casual Jeans* (2022-2024)

Berdasarkan Gambar 3, pola penjualan produk *casual jeans* periode 2022–2024 menunjukkan fluktuasi musiman yang konsisten dari tahun ke tahun. Puncak permintaan terjadi pada April, dengan penjualan masing-masing sebesar 115.491 pcs (2022), 128.381 pcs (2023), dan 138.549 pcs (2024). Setelah puncak tersebut, penjualan menurun pada pertengahan tahun, khususnya pada Juni–Juli, dengan volume berada pada kisaran 55.000–65.000 pcs. Pola ini mengindikasikan adanya musiman tahunan, di mana peningkatan permintaan umumnya terjadi pada Maret–April menjelang hari raya, serta kembali meningkat pada November–Desember yang merupakan periode akhir tahun.


Peramalan Permintaan Metode Holt-Winters

Metode Holt- Winters diterapkan dalam dua pendekatan, yaitu Holt-Winters *Additive* dan Holt-Winters *Multiplicative* untuk menentukan model yang paling sesuai dengan karakteristik data penjualan. Kedua model diestimasi menggunakan *software* RStudio dengan jumlah periode sebanyak 36 bulan, mencakup rentang waktu Januari 2022 hingga Desember 2024. Berdasarkan hasil *input* (1) dan (2), diperoleh nilai parameter *smoothing* seperti ditunjukkan pada Tabel 2 berikut.

Tabel 2. Parameter Holt-Winters

<i>Smoothing Parameters</i>	<i>Additive</i>	<i>Multiplicative</i>
Alpha (α)	0.2501	0.4286
Beta (β)	0,0001	0,0001
Gamma (γ)	0,0001	0.0013

Berdasarkan Tabel 2, pada model *Additive* nilai α (alpha) = 0,2501 menunjukkan bahwa model memberikan bobot yang cukup pada data terbaru dalam memperbarui estimasi level, namun tetap menjaga kestabilan agar tidak terlalu sensitif terhadap fluktuasi jangka pendek. Nilai β (beta) dan γ (gamma) yang sangat rendah mengindikasikan bahwa penyesuaian terhadap komponen tren dan musiman bersifat minimal, sehingga pola historis tetap terjaga secara konsisten. Sementara itu, pada model *Multiplicative*, nilai α (alpha) = 0,4286 menunjukkan respons model yang lebih cepat terhadap perubahan data aktual tanpa menimbulkan ketidakstabilan hasil peramalan. Nilai β (beta) = 0,0001 dan γ (gamma) = 0,0013 yang rendah menandakan bahwa penyesuaian tren dan musiman berlangsung secara halus dan stabil, menjaga pola fluktuasi sesuai kecenderungan historis data. Berikut visual hasil peramalan permintaan *casual jeans* model *Additive* dan *Multiplicative* pada Gambar 4.



Gambar 4. Plot Peramalan Model *Additive* dan *Multiplicative*

Visualisasi hasil peramalan untuk kedua model ditunjukkan pada Gambar 4, di mana garis hitam menggambarkan data aktual permintaan produk *casual jeans* dari tahun 2022 hingga awal 2024, sedangkan garis merah dan biru masing-masing merepresentasikan hasil peramalan dengan model *Additive* dan *Multiplicative*. Kedua model menunjukkan pola pergerakan yang serupa, dengan kecenderungan peningkatan tren permintaan di tahun 2025 serta pola musiman yang tetap konsisten mengikuti pola historis. Hasil peramalan permintaan bulanan menggunakan model Holt-Winters *Additive* dan *Multiplicative* disajikan pada Tabel 3 berikut.

Tabel 3. Hasil Peramalan Model *Additive* dan *Multiplicative* (Pcs)

Bulan	Periode (t)	<i>Additive</i>	<i>Multiplicative</i>
Januari	37	69.805	66.926
Februari	38	65.492	62.402
Maret	39	111.946	112.433
April	40	143.660	148.105
Mei	41	99.537	99.865
Juni	42	79.481	77.719
Juli	43	76.070	71.216
Agustus	44	91.617	88.934

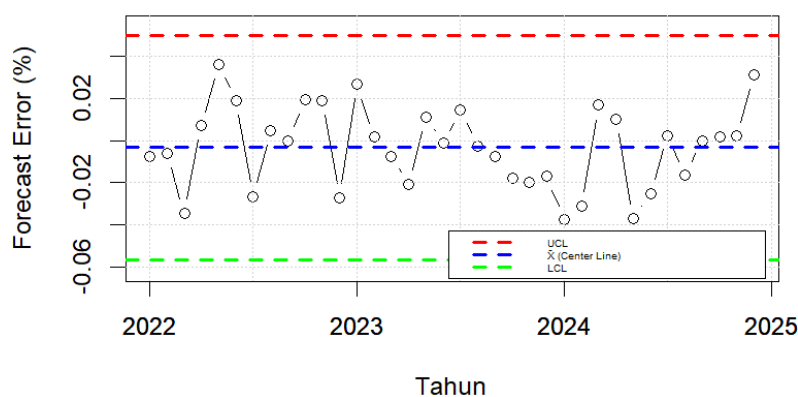
September	45	86.410	82.898
Oktober	46	102.325	101.831
November	47	114.944	116.810
Desember	48	127.431	133.893

Berdasarkan hasil pada Tabel 3, model *Additive* memprediksi puncak permintaan terjadi pada April 2025 sebesar 143.660 pcs, dan meningkat kembali pada Desember 2025 sebesar 127.431 pcs, sedangkan permintaan terendah diperkirakan pada Februari 2025 sebesar 65.492 pcs. Sementara itu, model *Multiplicative* memproyeksikan puncak permintaan tertinggi pada April 2025 sebesar 148.105 pcs dan meningkat kembali pada Desember 2025 sebesar 133.893 pcs, dengan titik terendah pada Februari 2025 sebesar 62.402 pcs. Pola ini menegaskan adanya karakteristik musiman tahunan yang konsisten, di mana permintaan meningkat menjelang pertengahan dan akhir tahun, sementara menurun di awal tahun. Hasil ini sejalan dengan pola musiman historis penjualan produk *casual jeans*, yang cenderung dipengaruhi oleh momentum hari raya serta akhir tahun. Kecenderungan pola tersebut kemudian diuji lebih lanjut melalui perhitungan tingkat kesalahan peramalan. Berdasarkan perhitungan uji verifikasi menggunakan MASE dan MAPE sesuai dengan input (14) diperoleh hasil sebagaimana ditampilkan pada Tabel 4 berikut.

Tabel 4. Perbandingan Hasil Uji Verifikasi Metode Holt-Winters

Metode	MASE	MAPE (%)
Holt-Winters <i>Additive</i>	0,3989	2,97
Holt-Winters <i>Multiplicative</i>	0,2279	1,55

Berdasarkan Tabel 4, model *Additive* menghasilkan nilai MASE sebesar 0,3989 menggambarkan bahwa performa model ini lebih baik dibandingkan metode peramalan sederhana (*naïve forecast*) karena kesalahan yang dihasilkan lebih rendah. Nilai MAPE sebesar 2,97%, juga menunjukkan bahwa tingkat kesalahan peramalan relatif kecil dan masuk kategori sangat akurat. Di sisi lain, model *Multiplicative* memberikan nilai MASE yang lebih kecil, yaitu 0,2279, serta nilai MAPE sebesar 1,55%. Hasil uji verifikasi menandakan bahwa model *Multiplicative* mampu mengikuti pola historis dengan lebih baik dan menghasilkan estimasi yang lebih presisi dibandingkan model *Additive*. Model *Multiplicative* terbukti lebih responsif terhadap perubahan baik lonjakan maupun penurunan sehingga menghasilkan peramalan yang lebih mendekati kondisi aktual [80]. Penelitian Kartika [81] pada toko *fashion* wanita juga memperlihatkan bahwa model *Multiplicative* dengan nilai MAPE 9,05% mampu menangkap variasi musiman yang semakin meningkat ketika penjualan berada pada level tinggi, terutama pada periode puncak seperti Ramadhan dan akhir tahun. Temuan tersebut kemudian diperkuat melalui proses uji validasi untuk memastikan kestabilan data dan konsistensi pola yang terbentuk. Salah satu tahapan validasi dilakukan dengan melihat grafik *Moving Range*, yang ditampilkan pada Gambar 5 berikut.



Gambar 5. Uji Validasi Model *Multiplicative*

Berdasarkan Gambar 5, hasil peramalan Holt-Winters *Multiplicative* menunjukkan seluruh titik residual berada dalam batas kendali antara 0,0496 dan 0,0563), sehingga tidak ada nilai yang melewati batas dan tidak ditemukan indikasi *out of control*. Garis tengah (\bar{X}) sebesar -0.0033 yang sangat dekat dengan nol menunjukkan bahwa model tidak memiliki bias signifikan dan kesalahan prediksi cenderung seimbang. Pola residual terlihat menyebar secara acak dan tidak membentuk pola tertentu seperti kecenderungan meningkat, menurun ataupun berulang secara periodik.

Peramalan Permintaan Metode SARIMA

Dalam penerapan metode SARIMA, proses pemodelan dilakukan melalui beberapa tahapan analisis untuk memastikan bahwa struktur data telah memenuhi syarat statistika yang diperlukan dengan tahapan sebagai berikut:

1. Stasioneritas

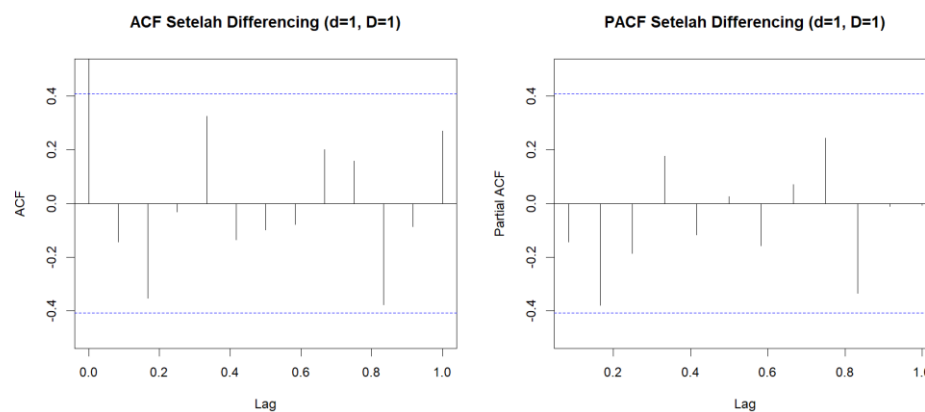
Tahap pertama dalam pemodelan SARIMA adalah menguji stasioneritas data untuk memastikan rata-rata dan variansnya relatif konstan dari waktu ke waktu. Berdasarkan input (4) hasil ADF dengan nilai p -value 0,06968 ($> 0,05$), yang berarti hipotesis nol diterima. Artinya, data pada level awal belum stasioner dan masih mengandung tren serta musiman. Oleh karena itu, diperlukan *differencing* untuk menstabilkan data sebelum tahap identifikasi model.

2. Differencing

Tahap berikutnya adalah melakukan *differencing* non-musiman ($d = 1$) untuk menghilangkan tren linear pada data menggunakan input (5). Namun, hasil ADF setelah *differencing* ini masih menunjukkan p -value 0,08668 ($> 0,05$), sehingga data belum stasioner. Karena data memiliki pola musiman tahunan, dilakukan *differencing* musiman ($D = 1, S = 12$) sesuai persamaan (6). Hasil ADF setelah *differencing* musiman saja juga belum stasioner dengan p -value 0,7235. Kondisi ini menunjukkan bahwa data memerlukan penghilangan tren dan musiman sekaligus, sehingga diterapkan kombinasi *differencing* non-musiman dan musiman ($d = 1, D = 1$) sesuai persamaan (7). Setelah kombinasi *differencing*, hasil ADF menunjukkan p -value 0,010 ($< 0,05$), menandakan bahwa data telah stasioner dan siap digunakan untuk tahap identifikasi parameter SARIMA.

3. Identifikasi Parameter Model (ACF dan PACF)

Tahap selanjutnya setelah data memenuhi asumsi stasioneritas adalah melakukan identifikasi parameter model melalui analisis ACF dan PACF dengan input (8). Plot ACF dan PACF setelah dilakukan proses *differencing* non-musiman dan musiman ($d=1, D=1$) ditunjukkan pada Gambar 6.



Gambar 6. Plot ACF dan PACF setelah dilakukan proses differensiasi


Berdasarkan Gambar 6, grafik ACF dan PACF setelah dilakukan *differencing* non-musiman dan musiman, pola autokorelasi pada *lag* awal masih terlihat, sementara pada *lag* berikutnya cenderung melemah dan berada di dalam batas signifikansi. Grafik PACF tidak menunjukkan pola *cut-off* yang jelas, sedangkan pada *lag* musiman tidak terlihat *spike* yang signifikan dan konsisten. Oleh karena itu, grafik ACF dan PACF digunakan sebagai indikasi awal terhadap model, sedangkan pemodelan SARIMA dilakukan lebih lanjut menggunakan prosedur otomatis dengan mempertimbangkan grafik ACF dan PACF.

4. Pemodelan SARIMA

Tahap selanjutnya adalah melakukan pemodelan menggunakan metode SARIMA untuk menentukan struktur model yang paling sesuai dengan karakteristik data penjualan produk *casual jeans*. Berdasarkan hasil seleksi otomatis menggunakan fungsi `auto.arima()` dengan input (9), diperoleh model terbaik yaitu SARIMA (0,1,1) (1,1,0) [12]. Model ini dipilih karena data memiliki pola musiman tahunan dan memerlukan *differencing* non-musiman serta musiman untuk mencapai kestasioneran. Komponen MA(1) menangkap variasi jangka pendek, sedangkan SAR(1) merepresentasikan pengaruh musiman tahunan, sehingga model mampu mengikuti perubahan tren bulanan sekaligus menjaga pola musiman yang konsisten.

5. Hasil Peramalan

Berdasarkan input (10), proses peramalan dilakukan menggunakan fungsi `forecast()` pada RStudio dengan model terbaik SARIMA (0,1,1) (1,1,0) [12] yang diperoleh dari tahap pemodelan sebelumnya. Gambar 7 menyajikan visualisasi hasil peramalan menggunakan model tersebut.



Gambar 7. Plot Peramalan Permintaan Tahun 2025 Model SARIMA

Visualisasi hasil peramalan pada Gambar 7 menunjukkan bahwa garis hitam menggambarkan data aktual permintaan produk *casual jeans* selama periode Januari 2022 hingga Desember 2024, sedangkan garis biru menunjukkan hasil peramalan menggunakan model SARIMA untuk periode Januari–Desember 2025. Terlihat bahwa model mampu mengikuti pola fluktuasi historis dengan baik, di mana permintaan meningkat pada awal dan akhir tahun, serta menurun pada pertengahan tahun. Tren kenaikan yang terjadi menjelang Maret, April dan November, Desember mengindikasikan bahwa penjualan dipengaruhi oleh pola konsumsi musiman, seperti peningkatan permintaan menjelang hari raya dan akhir tahun. Hasil peramalan untuk periode 12 bulan ke depan disajikan pada Tabel 5 berikut.

Tabel 5. Hasil Peramalan Permintaan Produk *Casual Jeans* Tahun 2025 Model SARIMA

Bulan	Periode (t)	Hasil (Pcs)
Januari	37	63.127
Februari	38	58.586
Maret	39	111.252
April	40	147.835
Mei	41	91.762
Juni	42	71.720
Juli	43	67.106
Agustus	44	81.549
September	45	77.742
Oktober	46	96.450
November	47	111.364
Desember	48	134.383

Berdasarkan hasil pada Tabel 5, model SARIMA memproyeksikan bahwa permintaan produk *casual jeans* pada tahun 2025 akan berfluktuasi dengan pola yang relatif stabil dengan total 1.112.876 pcs. Puncak permintaan diperkirakan terjadi pada April 2025 sebesar 147.835 pcs, yang kemudian kembali meningkat menjelang akhir tahun pada Desember 2025 sebesar 134.383 pcs. Sementara itu, permintaan terendah terjadi pada Februari 2025 dengan estimasi 58.586 pcs.

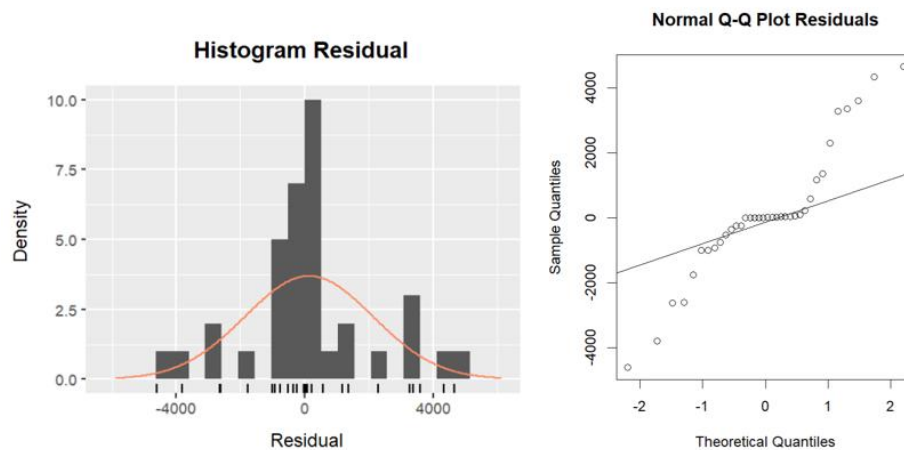
6. Uji Kelayakan Model (*Residual Analysis*)

- Uji *Coefficient Significance*

Hasil uji *coeftest* melalui input (11) menunjukkan bahwa parameter *Seasonal Autoregressive* (SAR1) signifikan dengan *p-value* 4,19e-08 (< 0,05), sedangkan parameter *Moving Average* (MA1) tidak signifikan *p-value* 0,09164 (> 0,05). Meskipun demikian, pemilihan model tidak hanya bergantung pada signifikansi parameter, tetapi juga pada nilai *Akaike Information Criterion* (AIC). Model SARIMA (0,1,1) (1,1,0) [12] dipertahankan karena memiliki AIC terkecil, yaitu 441,05, sehingga dianggap paling optimal [82]. Hal ini sejalan dengan penelitian Anwar dan Linda [83], yang menyatakan bahwa

pemilihan model deret waktu berdasarkan AIC terendah memberikan hasil peramalan yang lebih stabil dan akurat.

- Uji Normalitas Residual
 Berdasarkan hasil pengujian Kolmogorov–Smirnov dengan input (12), diperoleh nilai *p-value* sebesar 0,03396 ($< 0,05$), yang menunjukkan bahwa residual secara statistik tidak sepenuhnya berdistribusi normal. Namun, evaluasi visual melalui histogram dan Q–Q plot pada Gambar 8 menunjukkan distribusi residual mendekati normal, dengan pemusatan di sekitar nol dan penyimpangan minimal pada ekor [84].



Gambar 8. Histogram dan Q–Q Plot Residual Model SARIMA

Berdasarkan Gambar 8, meskipun residual tidak sepenuhnya normal secara statistik, secara visual residual terlihat cukup mendekati distribusi normal. Dalam literatur *forecasting* deret waktu, validitas model lebih ditentukan oleh apakah residual bersifat *white noise* (acak dan bebas autokorelasi) daripada distribusi normal yang sempurna [85]. Oleh karena itu, model SARIMA tetap dianggap layak digunakan untuk peramalan.

- Uji Autokorelasi Residual
 Uji Ljung–Box dilakukan untuk mengevaluasi ada tidaknya autokorelasi pada residual model, yang menentukan apakah pola data telah sepenuhnya tertangkap oleh model. Berdasarkan hasil input (13), *p-value* sebesar 0.3070 (> 0.05). Hasil ini menunjukkan bahwa tidak terdapat autokorelasi yang signifikan, sehingga residual dapat dikatakan bersifat acak (*white noise*). Artinya, model SARIMA (0,1,1) (1,1,0) [12] telah berhasil menangkap seluruh pola tren dan musiman pada data penjualan produk *casual jeans* secara efektif. Temuan ini sejalan dengan penelitian Ramadan [86] yang menyatakan bahwa hasil uji Ljung–Box dengan *p-value* > 0.05 menandakan model telah memenuhi asumsi independensi residual dan layak digunakan untuk peramalan.

Perbandingan Hasil Peramalan Permintaan

Untuk menentukan model peramalan yang paling sesuai dengan karakteristik data penjualan casual jeans, dilakukan evaluasi akurasi dengan membandingkan ukuran kesalahan, yaitu MASE dan MAPE. Perbandingan hasil uji verifikasi tersebut disajikan pada Tabel 6 berikut.

Tabel 6. Perbandingan Berdasarkan Uji Verifikasi

Model	MASE	MAPE (%)
Holt-Winters <i>Additive</i>	0,399	2,97
Holt-Winters <i>Multiplicative</i>	0,228	1,55
SARIMA (0,1,1) (1,1,0) [12]	0,216	1,43

Berdasarkan hasil uji verifikasi pada Tabel 6, model SARIMA (0,1,1) (1,1,0) [12] menunjukkan kinerja paling unggul dibandingkan dua model Holt-Winters. Model Holt-Winters *Additive* menghasilkan MASE sebesar 0,399 dan MAPE 2,97%, sedangkan model Holt-Winters *Multiplicative* sedikit lebih baik dengan MASE 0,228 dan MAPE 1,55%.

Meskipun kedua model tersebut mampu menangkap pola musiman dalam data, tingkat kesalahannya masih lebih tinggi dibandingkan model SARIMA, yang tercatat memiliki MASE 0,216 dan MAPE 1,43%. Temuan ini sejalan dengan studi lain, di mana model SARIMA (0,1,1) (1,1,0) [12] juga terbukti menjadi model terbaik pada berbagai konteks peramalan. Misalnya, dalam memprediksi harga LPG masa depan, SARIMA dipilih sebagai model terbaik dengan MAPE terkecil sebesar 7,27% [87]. Sejalan dengan itu, model yang sama juga terbukti unggul dalam meramalkan jumlah pasien dengan pendarahan saluran cerna, menunjukkan konsistensi kemampuan SARIMA (0,1,1) (1,1,0) [12] dalam menangani data deret waktu musiman dan menghasilkan prediksi yang akurat [88]. Setelah memperoleh hasil akurasi melalui uji verifikasi menggunakan MASE dan MAPE, langkah selanjutnya adalah membandingkan hasil peramalan masing-masing model dengan data aktual sesuai dengan Tabel 7 berikut.

Tabel 7. Perbandingan Hasil Peramalan dengan Data Aktual (Pcs)

Bulan	Periode (t)	Additive	Multiplicative	SARIMA (0,1,1)(1,1,0)[12].	Data Aktual
Januari	37	69.805	66.926	63.127	57.580
Februari	38	65.492	62.402	58.586	56.454
Maret	39	111.946	112.433	111.252	101.466
April	40	143.660	148.105	147.835	133.323
Mei	41	99.537	99.865	91.762	89.952
Juni	42	79.481	77.719	71.720	70.418
Juli	43	76.070	71.216	67.106	64.407
Agustus	44	91.617	88.934	81.549	80.327
September	45	86.410	82.898	77.742	76.711
Oktober	46	102.325	101.831	96.450	92.121

Berdasarkan Tabel 7, hasil prediksi model SARIMA (0,1,1) (1,1,0) [12] cenderung melebihi data aktual penjualan *casual jeans*, terutama pada bulan Januari 2025, di mana prediksi SARIMA sebesar 63.127 pcs dibandingkan dengan data aktual 57.580 unit. Meskipun prediksi melebihi nilai aktual, jika dilihat dari tingkat akurasi MAPE, model SARIMA tetap menunjukkan kesalahan paling kecil dibandingkan model Holt-Winters *Additive* dan *Multiplicative*, masing-masing dengan MAPE 13,58% dan 11,01%. Model SARIMA hanya menghasilkan MAPE 4,96%, jauh lebih rendah dibandingkan dua model lainnya, sehingga menegaskan bahwa SARIMA memberikan prediksi yang paling mendekati nilai aktual dan lebih stabil dalam menangkap pola musiman data. Sejalan dengan temuan ini, perbandingan SARIMA dan Holt-Winters untuk memprediksi suhu rata-rata Kota Padang menunjukkan bahwa SARIMA menghasilkan nilai *error* terkecil, sehingga lebih akurat [89].

Akurasi peramalan model SARIMA yang tinggi menunjukkan perusahaan dapat merencanakan produksi lebih tepat, mengurangi risiko *overstock*, dan menekan biaya penyimpanan [90]. Prediksi yang akurat juga meminimalkan penurunan nilai barang sehingga menjaga margin keuntungan perusahaan [91]. Selain itu, peramalan yang andal mendukung pengendalian persediaan lebih efisien, pengambilan keputusan strategis, serta perencanaan produksi, sehingga optimalisasi sumber daya dan profitabilitas perusahaan meningkat [92].

KESIMPULAN

Hasil penelitian menunjukkan bahwa metode SARIMA (0,1,1) (1,1,0) [12] memberikan peramalan permintaan *casual jeans* yang paling akurat dibandingkan metode Holt-Winters, dengan MASE 0,216 dan MAPE 1,43%. Model ini berhasil menangkap pola musiman dan tren penjualan secara konsisten, sehingga prediksi mendekati data aktual dan dapat dijadikan dasar dalam pengambilan keputusan produksi serta pengendalian persediaan. Temuan ini menegaskan bahwa pemilihan metode peramalan yang tepat dapat secara signifikan membantu perusahaan dalam mengurangi risiko *overstock* akibat produksi berlebih dan menekan biaya penyimpanan inventori. Meskipun demikian, penelitian ini memiliki keterbatasan, yakni data yang digunakan hanya mencakup tiga tahun terakhir dan belum memasukkan faktor eksternal yang dapat memengaruhi permintaan, seperti promosi. Sebagai arah penelitian lanjutan, disarankan untuk mengimplementasikan model SARIMAX yang memadukan variabel eksternal, sehingga peramalan dapat dilakukan secara lebih komprehensif dan mendukung perencanaan produksi serta pengelolaan persediaan yang lebih efektif dan efisien.

DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, “Ekonomi Indonesia Triwulan III-2024 tumbuh 1,50 persen (Q-to-Q).”, BPS. Accessed: Nov. 18, 2025. [Online]. Available: <https://www.bps.go.id/id/pressrelease/2024/11/05/2382>
- [2] N. K. Y. Diantari, “Tren new normal pada industri fast fashion di Indonesia: Adaptasi fast fashion di masa pandemi,” *Bhumidevi J. Fash. Des.*, vol. 1, no. 01, pp. 68–75, 2021.
- [3] Y. Fajriah, “Strategi Adaptasi UMKM Terhadap Perubahan Tren Konsumen Di Era Digital,” *J. Econ.*, vol. 4, no. 1, pp. 01–08, Jan. 2025, doi: 10.55681/economina.v4i1.1522.
- [4] M. F. O. Nugraheni, R. Windiani, and F. E. Wahyudi, “Tanggung Jawab Kapitalis: Strategi H&M Menanggulangi Dampak Negatif Industri Fast Fashion,” *J. Int. Relations Diponegoro*, vol. 8, no. 3, pp. 396–407, 2022, doi: <https://doi.org/10.14710/jirud.v8i3.34486>.
- [5] G. D. Saputra and E. Kurniati, “Analisis Implementasi Sistem Distribusi Dalam Menjaga Keseimbangan Permintaan Dan Penawaran Produk Pertanian Kakao Di Pesawaran, Provinsi Lampung,” *J. Ekon. Pertan. dan Agribisnis*, vol. 2, no. 2, pp. 114–127, 2025.
- [6] R. S. Handayani, G. A. Diva, E. N. Hermansyah, and A. Siswati, “Transformasi Digital E-Commerce di Era Post-Pandemic: Analisis Tren dan Dampak pada Perilaku Konsumen Indonesia,” *J. Inform. dan Kesehat.*, vol. 2, no. 2, pp. 108–117, Aug. 2025, doi: 10.35473/ikn.v2i2.3704.
- [7] C. Chandra, E. A. L. F. A. Hubeis, M. K. S. F. Kurniawan, and Nurhayati, “Strategi Operasional Untuk Menghadapi Fluktuasi Permintaan Per Kuartal Perusahaan FMCG,” *Integr. Perspect. Soc. Sci. J.*, vol. 2, no. 2, pp. 2120–2129, 2025, [Online]. Available: <https://ipssj.com/index.php/ojs/article/view/286>
- [8] A. Supriyanto, R. D. Permatasari, A. H. Prihastuti, T. Saputra, and M. A. Bora, “Kesuksesan Muslimah Pelaku UMKM: Peran Dimensi Entrepreneurial Orientation,” *BISNIS J. Bisnis dan Manaj. Islam*, vol. 10, no. 2, p. 267, Jan. 2023, doi: 10.21043/bisnis.v10i2.17740.
- [9] A. V. Yunita, A. L. A. Putri, and Y. Sulistyowati, “Strategi Efektif Pengendalian Persediaan Barang Jadi Dalam Bisnis Mochi AO Daifuku: Meningkatkan Efisiensi dan Kelayakan Operasional,” *J. Ekon. Pendidik. dan Pengabd. Masy.*, vol. 1, no. 1, pp. 8–15, 2024, doi: <https://doi.org/10.63200/jependimas.v1i1.16>.
- [10] I. Hassandi, M. R, and K. Zhasfia, “Marketing Risk Management For Business: Literature Review Approach,” *Media J. Account. Manag.*, vol. 1, no. 1, pp. 1–7, 2024.
- [11] N. N. S. A. Yanti, “Peran E-Commerce Terhadap Perilaku Konsumsi Dan Keputusan Pembelian Busana Adat Menjelang Hari Raya,” *Waisya J. Ekon. Hindu*, vol. 3, no. 1, pp. 27–40, Apr. 2024, doi: 10.53977/jw.v3i1.1606.
- [12] N. Nuraeni and B. Santoso, “Peranan Manajemen Persediaan Bahan Baku terhadap Penjadwalan Produksi PT XYZ,” *J. Bisnis Dan Manaj.*, vol. 2, no. 2, pp. 379–394, 2024, doi: <https://doi.org/10.61930/jurbisman.v2i2.614>.
- [13] J. Manurung *et al.*, “Pengaruh Penerapan Material Requirements Planning (MRP) Terhadap Efisiensi Manajemen Persediaan Pada Perusahaan Manufaktur,” *Econ. Digit. Bus. Rev.*, vol. 7, no. 1, pp. 197–207, 2025, doi: <https://doi.org/10.37531/ecotal.v7i1.2889>.
- [14] U. S. Sulistyawati and Munawir, “Decoding Big Data: Mengubah Data Menjadi Keunggulan Kompetitif dalam Pengambilan Keputusan Bisnis,” *J. Manaj. dan Teknol.*, vol. 1, no. 2, pp. 58–71, Nov. 2024, doi: 10.63447/jmt.v1i2.1114.
- [15] R. R. Fauzi, “Analisis perkiraan penjualan produk batik pada UD. Rumah Batik Sibuhuan menggunakan metode Arima,” UIN Syekh Ali Hasan Ahmad Addary Padangsidempuan, 2025. [Online]. Available: <https://etd.uinsyahada.ac.id/12482/>
- [16] E. Tasia, N. Nazira, Q. A’yuniyah, M. H. Fikri, and A. N. Am, “Analisis Model Manajemen Permintaan SCM dan Peramalan Penjualan Busana Menggunakan Metode Holt-Winter Exponential Smoothing,” *J. Tek. Ind. Terintegrasi*, vol. 6, no. 4, pp. 1303–1312, Oct. 2023, doi: 10.31004/jutin.v6i4.20313.
- [17] N. E. Susanti, R. Saputra, and I. A. Situmorang, “Perbandingan Metode SARIMA, Double Exponential Smoothing dan Holt-Winter Additive dalam Peramalan Retail Sales Mobil Honda,” *J. Sains Mat. dan Stat.*, vol. 10, no. 1, p. 58, Mar. 2024, doi: 10.24014/jsms.v10i1.26375.
- [18] H. A. Khoiri, *Analisis Deret Waktu Univariat*. Kota Madiun: UNIPMA PRESS, 2023.
- [19] F. Ahmad, “Penentuan Metode Peramalan Pada Produksi Part New Granada Bowl St di PT.X,” *JISI J. Integr. Sist. Ind.*, vol. 7, no. 1, pp. 31–39, May 2020, doi: 10.24853/jisi.7.1.31-39.
- [20] I. A. Prakoso, Kusnadi, and B. Nugraha, “Peramalan Penjualan Produk Dengan Metode Regresi Linear Dan Aplikasi POM-QM di PT XYZ,” *Widya Tek.*, vol. 20, no. 1, pp. 17–20, 2021.
- [21] T. Hidayat, A. Khairani, S. A. Putri, and Febriyanto, “Implementasi Metode Peramalan Moving Average dan Single Exponential Smoothing dalam Memprediksi Kebutuhan Bearing pada PT XYZ,”

- Integr. J. Ilm. Tek. Ind.*, vol. 10, no. 1, pp. 45–54, Apr. 2025, doi: 10.32502/integrasi.v10i1.431.
- [22] M. Bustomy and A. Bakhtiar, “Forecasting Permintaan Produk Keripik Sayur Mix di PT IPL Menggunakan Metode Time Series,” *J. Agribest*, vol. 9, no. 1, pp. 45–56, 2025, doi: <https://doi.org/10.32528/agribest.v9i1.3309>.
- [23] H. Kusdarwati, U. Effendi, and S. Handoyo, *Analisis Deret Waktu Univariat Linier: Teori dan Terapannya dengan Rstudio*. Kota Malang: UB Press, 2022.
- [24] D. Nurdiansyah and A. Sulistiawan, *Dasar pemrograman komputer dengan open source software R (Untuk bidang sains dan teknologi)*. Kota Serang: CV. AA. RIZKY, 2023.
- [25] S. A. Dwi and S. Kahabing, *Analisis dan Visualisasi Data Berbasis Cloud*. Kabupaten Banjarnegara: PT Penerbit QRiset Indonesia, 2025.
- [26] R. Kaestria, E. F. Himmah, and R. Irawan, “Penerapan Matplotlib dalam Visualisasi Data untuk Analisis Hubungan Penggunaan Gadget dan Hasil Belajar,” *J. Digit. Bus. Inf. Technol.*, vol. 1, no. 1, pp. 29–39, Jun. 2024, doi: 10.23971/jobit.v1i1.204.
- [27] K. Sussolaikah, “Pemanfaatan Packages Pada R Programming Untuk Crawling Data Pada Social Media,” *Build. Informatics, Technol. Sci.*, vol. 3, no. 3, pp. 203–206, Dec. 2021, doi: 10.47065/bits.v3i3.1035.
- [28] A. J. F. dos Santos *et al.*, “Statistical analysis between 2006 and 2019 and forecast of rabies in cattle from 2020 to 2022 in Tocantins State (Brazil), by using the R Studio software,” *Epidemiol. Infect.*, vol. 150, p. e82, Mar. 2022, doi: 10.1017/S0950268822000553.
- [29] A. Mogi and Lativa, “Pengaruh Ekspor dan Impor Terhadap Pertumbuhan Ekonomi Di Indonesia Pada Tahun 2018-2022.,” *J. Portofolio J. Manaj. dan Bisnis*, vol. 2, no. 3, pp. 230–238, 2023.
- [30] N. Iman and A. M. Ishikarima, *What R We Doing Here: Panduan Analisis Data dengan R untuk Penelitian Bisnis dan Manajemen*. Yogyakarta: Gadjah Mada Univercity Press, 2025.
- [31] S. H. Nur, H. Hikmah, and R. Rahmawati, “Model Regresi Cox Proportional Hazard dengan Penaksiran Parameter Efron Partial Likelihood,” *J. Math. Theory Appl.*, vol. 6, no. 2, pp. 192–203, Oct. 2024, doi: 10.31605/jomta.v6i2.3907.
- [32] G. Theofani and E. Sedyono, “Multiple Linear Regression Analysis on Factors that Influence Employees Work Motivation,” *Sinkron*, vol. 7, no. 3, pp. 791–798, Jul. 2022, doi: 10.33395/sinkron.v7i3.11453.
- [33] S. Siregar, “Prediksi Jumlah Penumpang Pesawat Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA),” Universitas Medan Area, 2023. [Online]. Available: <https://repositori.uma.ac.id/handle/123456789/22696>
- [34] L. Wati and A. Solichin, “Prediksi Nilai Pengadaan Barang dan Jasa Pada Sebuah Perusahaan Pariwisata Menggunakan Metode ARIMA dan Fuzzy Time Series,” *INOVTEK Polbeng - Seri Inform.*, vol. 9, no. 1, Jun. 2024, doi: 10.35314/isi.v9i1.4041.
- [35] W. Nurlaela, A. I. Pratiwi, and H. T. Yulianti, “Analisis Metode Moving Average, Exponential Smoothing, dan Arima dalam Peramalan Permintaan untuk Pengendalian Stok Floor Rear,” *J. Teknol. dan Manaj. Ind. Terap.*, vol. 4, no. 3, pp. 1066–1075, Sep. 2025, doi: 10.55826/jtmit.v4i3.1134.
- [36] P. M. Al Khusna, “Perbandingan metode triple exponential smoothing holt-winters model additive dan multiplicative untuk prediksi indeks harga konsumen,” Universitas Islam Negeri Maulana Malik Ibrahim, 2024.
- [37] V. Sarasi, I. Chaerudin, N. D. Satmoko, and D. A. Zahra, “Analysis Of Holt-Winters And Arima Model In Muslimah Scarf Demand Forecasting,” *J. Bisnis dan Manaj.*, vol. 24, no. 1, pp. 59–69, 2023.
- [38] P. Kačmárý and N. Lörinc, “Possibilities of Sale Forecasting Textile Products with a Short Life Cycle,” *Sustainability*, vol. 15, no. 21, p. 15517, Nov. 2023, doi: 10.3390/su152115517.
- [39] I. R. Amalia, T. Widiharih, and T. Tarno, “Holt Winters Exponential Smoothing Untuk Meramalkan Produk Domestik Bruto di Indonesia,” *J. Gaussian*, vol. 13, no. 1, pp. 219–229, Oct. 2024, doi: 10.14710/j.gauss.13.1.219-229.
- [40] J. Rizal, R. F. Haryanti, and W. Agwil, “A Comparison of the Holt-Winters Additive and Multiplicative Methods with Grid search Optimization in Forecasting Red Chili Prices in Bengkulu City,” *J. Mat. Stat. dan Komputasi*, vol. 22, no. 1, pp. 199–218, Sep. 2025, doi: 10.20956/j.v22i1.45755.
- [41] R. K. Nur *et al.*, “Metode Triple Exponential Smoothing Untuk Peramalan Indeks Harga Konsumen Kota Surabaya Tahun 2020-2023,” *Pros. Semin. Nas. SAINS DATA*, vol. 4, no. 1, pp. 615–623, Sep. 2024, doi: 10.33005/senada.v4i1.294.
- [42] C. M. Mauliza, D. S. Susanti, and Khairizanurrahman, “Forecasting Sambungan Ptam: Double Exponential Smoothing & Holt-Winters Method,” *J. Stat. Ind. dan Komputasi*, vol. 10, no. 2, pp. 23–33, 2025.

- [43] Y. D. Rosita and L. S. Moonlight, "Perbandingan Metode Prediksi untuk Nilai Jual USD: Holt-Winters, Holt's, dan Single Exponential Smoothing," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 5, no. 4, pp. 322–333, Jan. 2024, doi: 10.35746/jtim.v5i4.473.
- [44] P. Bacher *et al.*, "Onlineforecast: An R Package for Adaptive and Recursive Forecasting," *R J.*, vol. 15, no. 1, pp. 173–194, Sep. 2023, doi: 10.32614/RJ-2023-031.
- [45] A. Mustopa, J. D. Santoso, M. S. F. Nauvaldhi, and D. Wulandari, "Pemodelan Variabilitas Musiman dalam Curah Hujan : Pendekatan Deret Waktu," *J. Inf. Syst. Manag.*, vol. 6, no. 2, pp. 148–155, Jan. 2025, doi: 10.24076/joism.2025v6i2.1936.
- [46] P. Negre, R. S. Alonso, J. Prieto, Ó. García, and L. De-la-Fuente-Valentín, "Prediction of footwear demand using Prophet and SARIMA," *Expert Syst. Appl.*, vol. 255, p. 124512, Dec. 2024, doi: 10.1016/j.eswa.2024.124512.
- [47] M. H. Syarif, N. M. Maghfur, and B. A. Dermawan, "Peramalan Tren Produk Pakaian Menggunakan Metode SARIMA pada Data Google Trends," *J. Ilm. Wahana Pendidik.*, vol. 9, no. 8, pp. 350–359, 2023, doi: <https://doi.org/10.5281/zenodo.7886616>.
- [48] L. Junaedi, N. Damastuti, L. Latipah, and A. Widodo, "Penerapan Metode Seasonal ARIMA (SARIMA) untuk Peramalan Penjualan Barang dengan Pola Musiman Tahunan.," *JISEM (Jurnal Inform. Sist. Informasi, dan Elektro Mod.*, vol. 1, no. 1, pp. 38–48, 2025, doi: <https://doi.org/10.33508/jisem.v1i01.7403>.
- [49] N. Qisthi, S. L. Fitri, A. Immanuel, and D. D. Dewi, "Prediksi Harga Emas Untuk Investasi Masa Depan Menggunakan Model Seasonal Autoregressive Integrated Moving Average (SARIMA).," *J. Innov. Res. Knowl.*, vol. 4, no. 7, pp. 4183–4194, 2024, doi: <https://doi.org/10.53625/jirk.v4i7.9053>.
- [50] L. D. Jayanti, R. Lestari, F. A. D. Suparno, and Fachruzzaki, "Prediksi Harga Emas Tahun 2024-2025 dengan Metode Autoregressive Integrated Moving Average (ARIMA) pada Aplikasi RStudio," *MARAS J. Penelit. Multidisiplin*, vol. 3, no. 4, pp. 1275–1289, 2025, doi: <https://doi.org/10.60126/maras.v3i4.1253>.
- [51] S. Deviana, Nusyirwan, D. Azis, and P. Ferdia, "Analisis model autoregressive integrated moving average data deret waktu dengan metode momen sebagai estimasi parameter," *J. Siger Mat.*, vol. 2, no. 2, pp. 57–67, 2021.
- [52] D. Wahyudi and I. V. Papatungan, "Peramalan Curah Hujan Dengan Model Seasonal Autoregressive Integrated Moving Average (SARIMA) terhadap Stasiun Meteorologi Fatmawati Soekarno Kota Bengkulu," *AUTOMATA*, vol. 3, no. 2, 2022.
- [53] A. Perdana and A. Zubair, "Penerapan Python untuk Visualisasi Dan Peramalan Pada Nilai Tukar USD/IDR Menggunakan Metode SARIMA," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 5, pp. 7788–7797, Jul. 2025, doi: 10.36040/jati.v9i5.14835.
- [54] S. J. C. Wulan, "Peramalan Jumlah Penumpang Kereta Api Di Jabodetabek Menggunakan Metode Hybrid Autoregressive Integrated Moving Average-Radial Basis Function Neural Network (ARIMARBFNN)," Muhammadiyah University, 2021.
- [55] F. R. Pradhana, M. Fahmi, and Z. A. Rizki, "Analisis Data Penjualan untuk Mengidentifikasi Pola Musiman dan Mengoptimalkan Strategi Bisnis di Unida Mart Gontor," *Naratif J. Nas. Riset, Apl. dan Tek. Inform.*, vol. 6, no. 2, pp. 152–157, Dec. 2024, doi: 10.53580/naratif.v6i2.303.
- [56] H. Kuswanto, P. E. P. Utomo, U. Khaira, and A. Waladi, "Prediksi Nilai Ekspor Migas Indonesia Menggunakan Metode SARIMA dan LSTM," *SATESI J. Sains Teknol. dan Sist. Inf.*, vol. 5, no. 1, pp. 69–79, Apr. 2025, doi: 10.54259/satesi.v5i1.4103.
- [57] Marisa, L. Pimpi, and Alfian, "Analisis Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) dan Penerapannya untuk Meramalkan Penjualan Motor Yamaha Di Indonesia," *J. Mat. Komputasi dan Stat.*, vol. 5, no. 1, pp. 848–856, Apr. 2025, doi: 10.33772/jmks.v5i1.117.
- [58] B. L. Pradhana, "Time Series Forecasting of LQ45 Stock Index Using ARIMA: Insights and Implications," *Rev. Manag. Account. Tour. Stud.*, vol. 1, no. 1, pp. 27–40, 2025, doi: <https://doi.org/10.51170/jmabr.v1i1.160>.
- [59] S. I. N. Suwandi, R. Tyasnurita, and H. Muhayat, "Peramalan Emisi Karbon Menggunakan Metode SARIMA dan LSTM," *J. Comput. Sci. Informatics Eng.*, vol. 6, no. 1, pp. 73–80, Jun. 2022, doi: 10.29303/jcosine.v6i1.436.
- [60] M. A. Putra and S. Andryana, "Perbandingan Algoritma ARIMA dan LSTM dalam Peramalan Tingkat Konsentrasi Co2 Emisi Atmosfer Untuk Masa Mendatang," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 3, pp. 4150–4157, May 2025, doi: 10.36040/jati.v9i3.13511.
- [61] N. P. Astuti and R. Bakri, "Implementasi forecastHybrid Package menggunakan R Studio Cloud untuk Prediksi Pertumbuhan Dana Pihak Ketiga dan Pembiayaan Pada Bank Muamalat Indonesia," *J. Sist.*

- Info. Bisnis*, vol. 11, no. 2, pp. 97–104, Dec. 2021, doi: 10.21456/vol11iss2pp97-104.
- [62] G. Christie, D. Hatidja, and R. Tumilaar, “Penerapan Metode SARIMA dalam Model Intervensi Fungsi Step untuk Memprediksi Jumlah Pegunjung Objek Wisata Londa (Application of the SARIMA Method in the Step Function Intervention to Predict the Number of Visitors at Londa Tourism Object),” *J. Ilm. SAINS*, vol. 22, no. 2, p. 96, Aug. 2022, doi: 10.35799/jis.v22i2.40961.
- [63] P. Bastian, “Detecting Relevant Deviations From the White Noise Assumption for Non-Stationary Time Series,” *J. Time Ser. Anal.*, Jul. 2025, doi: 10.1111/jtsa.70005.
- [64] J. Jauhari and I. Wibowo, “Pengaruh Strategi Pemasaran dan Kualitas Layanan Terhadap Kinerja Pemasaran dengan Tenaga Pemasaran Sebagai Variable Intervening di PT Zurich Topas Life Jakarta,” *J. Sos. Teknol.*, vol. 5, no. 3, pp. 617–639, Mar. 2025, doi: 10.59188/journalsostech.v5i3.32045.
- [65] S. Hidayati, A. H. Asyhar, and A. Krisnawan, “Analisis Pengaruh Jumlah Nilai Taksiran Dan Uang Pinjaman Terhadap Laba Bersih PT Pegadaian Kanwil XII Surabaya,” *J. Math. Educ. Sci.*, vol. 8, no. 1, pp. 9–15, Apr. 2025, doi: 10.32665/james.v8i1.3462.
- [66] I. S. Landa, D. Hatidja, and Y. A. . Langi, “Peramalan Indeks Harga Konsumen Di Kota Palu Menggunakan Metode Arima (Autoregressive Integrated Moving Average) Dalam Model Intervensi Fungsi Step,” *Indones. J. Intell. Data Sci.*, vol. 3, no. 1, pp. 28–38, May 2024, doi: 10.35799/ijids.v3i1.55581.
- [67] D. Sunaryo, Hamdan, A. Anggriani, C. Winata, and D. D. Alumi, “Corporate Financial Risk Trend Prediction Using ARIMA-Based Machine Learning: A Semantic Literature Review,” *J. Akunt. Manaj.*, vol. 3, no. 2, pp. 78–94, Nov. 2024, doi: 10.30656/jakmen.v3i2.9704.
- [68] R. Vikaliana and F. Sutisna, “Analisis Perencanaan Produksi LPG Menggunakan Pendekatan Forecasting,” *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 12, no. 1, pp. 90–95, Jun. 2024, doi: 10.37905/euler.v12i1.25317.
- [69] M. F. Andreyanto and H. C. Wahyuni, “Refining Sugar Production Forecasts: Analyzing Forecasting Techniques for Operational Precision,” *Procedia Eng. Life Sci.*, vol. 7, pp. 620–627, Mar. 2024, doi: 10.21070/pels.v7i0.1558.
- [70] M. D. Rizqi, R. D. Aulia, and U. Mahmudah, “Prediksi Tren Penggunaan Electronic Money (E-Money) di Indonesia menggunakan pendekatan Extreme Learning Machines,” *Emerg. Stat. Data Sci. J.*, vol. 3, no. 3, pp. 640–649, Oct. 2025, doi: 10.20885/esds.vol3.iss.3.art17.
- [71] M. Syahrul, H. Syafwan, and Y. Apridonal, “Prediksi Persediaan Oli Sepeda Motor Di Bengkel Amin Dengan Metode Simple Moving Average,” *J. Res. Eng. Technol. Appl. Sci.*, vol. 1, no. 1, pp. 36–45, 2024.
- [72] A. A. Correndo *et al.*, “metrica: an R package to evaluate prediction performance of regression and classification point-forecast models,” *J. Open Source Softw.*, vol. 7, no. 79, p. 4655, Nov. 2022, doi: 10.21105/joss.04655.
- [73] S. H. Mileniadewi, “Peramalan Kebutuhan Dan Usulan Perencanaan Safety Stock Bahan Baku Crude Oil Pada Unit Kilang PPSDM Migas Cepu Dengan Metode Time Series,” *Ind. Eng. Online J.*, vol. 11, no. 3, 2022.
- [74] D. M. Nugraha, “Penerapan Analisis Time Series Dalam Peramalan Penjualan Berbasis WEB (Studi Kasus: Ramen Kaizenka),” Universitas Kuningan, 2025.
- [75] F. Hendajani, I. P. Wardhani, S. Widayati, and S. Soegijanto, “Data Analisis Permintaan Barang dengan Metode Peramalan,” *EKOMABIS J. Ekon. Manaj. Bisnis*, vol. 3, no. 02, pp. 169–180, Aug. 2023, doi: 10.37366/ekomabis.v3i02.254.
- [76] M. Waruwu, “Pendekatan Penelitian Pendidikan: Metode Penelitian Kualitatif, Metode Penelitian Kuantitatif dan Metode Penelitian Kombinasi (Mixed Method),” *J. Pendidik. tambusai*, vol. 7, no. 1, pp. 2896–2910, 2023.
- [77] H. Syahrizal and M. S. Jailani, “Jenis-Jenis Penelitian Dalam Penelitian Kuantitatif dan Kualitatif,” *J. QOSIM J. Pendidik. Sos. Hum.*, vol. 1, no. 1, pp. 13–23, May 2023, doi: 10.61104/jq.v1i1.49.
- [78] H. S. Widiawati and L. Linawati, “Analisis Pengaruh Profitabilitas dan Leverage Terhadap Nilai Perusahaan dengan Corporate Social Responsibility sebagai Variabel Pemoderasi,” *JAE (JURNAL Akunt. DAN Ekon.*, vol. 7, no. 1, pp. 11–21, Mar. 2022, doi: 10.29407/jae.v7i1.17543.
- [79] F. I. Amalia, S. Imam, and Muryeti, “Peramalan Permintaan Kemasan Inner Box Menggunakan Metode Winter Exponential Smoothing Dan Multiplicative Decomposition,” in *Seminar Nasional Teknologi Cetak dan Media Kreatif*, 2024, pp. 33–39.
- [80] A. Agustin and R. Faulina, “Penerapan Metode Holt-Winters Untuk Peramalan Penjualan Lemari Pakaian 6 Pintu:(Studi Kasus: Jumlah Pesanan Toko Homebaze Living),” in *Prosiding Seminar Nasional Sains dan Teknologi "SainTek"*, 2025, pp. 125–141.

- [81] D. Kartika, “Implementasi Metode Triple Exponential Smoothing Pada Sistem Peramalan Penjualan Berbasis WEB (Studi Kasus: Planet Fashion Kuningan),” Universitas Kuningan, 2025.
- [82] Y. A. Nugroho and H. A. Hutahaean, “Integrasi Model Sarima dengan Optimasi Algoritma Genetika dalam Peramalan Penjualan Sepeda Motor di Indonesia,” *J. Ilm. Tek. Inform.*, vol. 26, no. 2, pp. 32–40, 2025.
- [83] R. Anwar and L. Rasiyanti, “Analisis Komparasi Model Peramalan Prophet Dan Arima Dalam Memprediksi Harga Saham Penutupan PT ANTM,” *Lattice J. J. Math. Educ. Appl.*, vol. 5, no. 1, pp. 57–74, Jun. 2025, doi: 10.30983/lattice.v5i1.9478.
- [84] I. K. Sumerta and E. J. Sari, “Pengaruh Komunikasi dan Koordinasi Terhadap Efektivitas Kinerja Karyawan Pada PT Pertamina (Persero) Patra Niaga Integrated Terminal Banjarmasin,” *J. Locus Penelit. dan Pengabd.*, vol. 4, no. 5, pp. 2028–2047, 2025.
- [85] H. Hassani, L. M. Mashhad, M. Royer-Carenzi, M. R. Yeganegi, and N. Komendantova, “White Noise and Its Misapplications: Impacts on Time Series Model Adequacy and Forecasting,” *Forecasting*, vol. 7, no. 1, p. 8, Feb. 2025, doi: 10.3390/forecast7010008.
- [86] R. Ramadan and R. Fitriani, “Perencanaan Safety Stock Menggunakan Metode Peramalan pada Proses Produksi Kemasan PT Empat Perdana Karton.,” *JIE (Journal Ind. Eng. Sci. J. Res. Appl. Ind. Syst.)*, vol. 10, no. 1, pp. 54–65, 2025, doi: <https://doi.org/10.33021/jie.v10i01.83>.
- [87] T. J. Sankar, I. A. A. Mary, and P. Sameerabanu, “Stochastic Modelling and Forecasting for LPG Prices: SARIMA Approach,” *J. Algebr. Stat.*, vol. 13, no. 2, pp. 3362–3370, 2022.
- [88] Z. Fu *et al.*, “Establishment and Evaluation of a Time Series Model for Predicting the Seasonality of Acute Upper Gastrointestinal Bleeding,” *Int. J. Gen. Med.*, vol. Volume 14, pp. 2079–2086, May 2021, doi: 10.2147/IJGM.S299208.
- [89] F. V. Putri, E. Ikhsan, and F. Fitri, “Peramalan Suhu Rata – Rata Kota Padang Panjang dengan Membandingkan Metode SARIMA dan Holt – Winter Additive,” *VARIANSI J. Stat. Its Appl. Teach. Res.*, vol. 6, no. 3, pp. 107–118, 2024, doi: <https://doi.org/10.35580/variansiunm237>.
- [90] Y. Pratomo, E. Priadi, S. A. Pamungkas, D. Fatrohimi, A. A. A. P. Ramadhan, and W. Setiafindari, “Analisis Pengendalian Persediaan Bahan Baku Pada PT Aneka Adhilogam Karya Menggunakan Metode Just In Time,” *J. Ilm. Res. Dev. STUDENT*, vol. 3, no. 1, pp. 171–178, Dec. 2024, doi: 10.59024/jis.v3i1.1073.
- [91] M. R. Octamara, Y. E. Prawatya, and I. Sujana, “Perencanaan dan Pengendalian Bahan Baku Produksi Kue Lapis pada UMKM XYZ di Kota Pontianak,” *J. Tek. Ind. Univ. Tanjungpura*, vol. 9, no. 2, pp. 259–266, 2025.
- [92] M. F. Nona, A. Rengga, and E. Luju, “Peran Pengelolaan Persediaan Barang dalam Meningkatkan Efisiensi Keuangan di CV Sumber Jaya Putra Perkara,” *Lokawati J. Penelit. Manaj. dan Inov. Ris.*, vol. 3, no. 6, pp. 197–207, Oct. 2025, doi: 10.61132/lokawati.v3i6.2307.