

Perbandingan Metode Peramalan Volume Transaksi Sistem Resi Gudang: *Prophet*, *Exponential Smoothing* dan *Sarima*

Vickie Ashri Noviani Sugianto¹, Ghiffari Ahnaf Danarwindu^{2,*}, Harry Prihatmoko³

^{1,2} Program Studi Statistika, Universitas Islam Indonesia, Jl. Kaliurang KM 14,5, Kabupaten Sleman Daerah Istimewa Yogyakarta, 55584, Indonesia

³ Badan Pengawas Perdagangan Berjangka Komoditi, Jl. M.I. Ridwan Rais No. 5, Jakarta Pusat, 10110, Indonesia

*Corresponding author: ghiffari.ahnaf@uii.ac.id



P-ISSN: 2986-4178
E-ISSN: 2988-4004

Riwayat Artikel

Dikirim: 11 Mei 2025
Direvisi: 24 Mei 2025
Diterima: 26 Mei 2025

ABSTRAK

Fluktuasi harga komoditas saat panen raya sering menyebabkan rendahnya pendapatan petani dan kesulitan akses pembiayaan. Sistem Resi Gudang (SRG) dirancang sebagai solusi untuk menstabilkan harga dan memberi akses pembiayaan tanpa agunan tambahan, serta mendukung ketahanan pangan nasional. Meskipun SRG terus berkembang, implementasinya masih menghadapi tantangan seperti keterbatasan kapasitas gudang, infrastruktur yang belum merata, dan perbedaan karakteristik komoditas. Peramalan volume komoditas yang masuk diperlukan untuk mengoptimalkan penggunaan gudang dan mendukung kebijakan logistik serta penyimpanan. Penelitian ini membandingkan tiga metode peramalan deret waktu yaitu *Prophet*, *Exponential Smoothing (Holt-Winters)*, dan *SARIMA*. Menggunakan data bulanan volume Resi Gudang dari Januari 2022 hingga Desember 2024. Evaluasi akurasi model dilakukan dengan *Mean Absolute Scaled Error (MASE)*. *Prophet* dengan konfigurasi *multiplicative* memberikan akurasi tertinggi dengan *MASE* 0,4134, namun menghasilkan prediksi negatif pada awal 2025. *Holt-Winters* menghasilkan prediksi yang lebih stabil dan realistis meski nilai *MASE*-nya lebih tinggi (0,7875). *SARIMA* memiliki performa terendah dengan *MASE* 0,9097. Hasil ini menunjukkan bahwa pemilihan model tidak hanya bergantung pada nilai *error*, tetapi juga pada hasil yang diperoleh. Peramalan volume SRG yang akurat dapat meningkatkan efisiensi operasional gudang, mencegah kekurangan kapasitas, serta mendukung stabilitas harga dan pengambilan kebijakan strategis.

kata kunci: Sistem Resi Gudang, *Forecasting*, *Prophet*, *Exponential Smoothing*, *SARIMA*.

ABSTRACT

Price fluctuations of commodities during the main harvest season often result in low farmer income and difficulties in accessing financing. The Warehouse Receipt System (WRS) is designed as a solution to stabilize prices and provide access to financing without additional collateral, as well as support national food security. Although WRS continues to develop, its implementation still faces challenges such as limited warehouse capacity, uneven infrastructure, and differences in commodity characteristics. Forecasting the volume of commodities entering the system is needed to optimize warehouse utilization and support logistics and storage policies. This study compares three time series Forecasting methods, namely Prophet, Exponential Smoothing (Holt-Winters), and SARIMA. Using monthly data of Warehouse Receipt volumes from January 2022 to December 2024. Accuracy evaluation of the models is conducted using the Mean Absolute Scaled Error (MASE). Prophet with a multiplicative configuration provides the highest accuracy with a MASE of 0.4134, but produces negative predictions in early 2025. Holt-Winters yields more stable and realistic predictions despite a higher MASE value (0.7875). SARIMA has the lowest performance with a MASE of 0.9097. These results indicate that model selection is not only based on error values, but also on the resulting forecasts. Accurate Forecasting of WRS volumes can improve warehouse operational efficiency, prevent capacity shortages, and support price stability and strategic decision-making.

keywords: Warehouse Receipt System, Forecasting, Prophet, Exponential Smoothing, SARIMA.

1. Pendahuluan

Sistem Resi Gudang (SRG) merupakan instrumen strategis yang diatur dalam Undang-Undang Nomor 9 Tahun 2006 tentang Sistem Resi Gudang. SRG dirancang untuk memberdayakan para pelaku usaha. SRG merujuk pada mekanisme yang mencakup penerbitan, pengalihan, penjaminan, dan penyelesaian transaksi Resi Gudang[1]. SRG memberi kemudahan bagi petani, nelayan, dan pelaku usaha untuk menyimpan komoditas di gudang yang telah terdaftar dan menerima resi sebagai bukti kepemilikan[2]. Resi Gudang dapat dipindahtangankan, dijadikan jaminan utang tanpa agunan tambahan, atau sebagai dokumen sah penyerahan barang[1].

Penerapan SRG sejalan dengan Asta Cita Kedua dalam visi Presiden dan Wakil Presiden Indonesia, yaitu memantapkan sistem pertahanan dan keamanan serta mendorong kemandirian bangsa melalui swasembada pangan[3]. Tantangan utama swasembada pangan adalah fluktuasi harga komoditas, terutama saat panen raya, yang menurunkan pendapatan petani dan menyulitkan mereka dalam permodalan[4][5]. Salah satu kebijakan strategis yang diimplementasikan untuk mencapai swasembada pangan adalah melalui Sistem Resi Gudang. SRG memungkinkan petani menunda penjualan hingga harga membaik, meningkatkan daya tawar, dan memperoleh pembiayaan tanpa agunan tambahan. SRG juga menjamin mutu komoditas, mempermudah transaksi lewat Pasar Lelang, menjaga stok nasional, mendukung agroindustri, serta meningkatkan efisiensi

logistik dan distribusi. Selain itu, SRG berkontribusi kepada pemerintah dan mendorong pertumbuhan industri perdagangan serta sektor usaha terkait lainnya[6].

Sejak 2008, SRG terus berkembang dengan 176 gudang di 29 provinsi dan 144 kabupaten/kota, baik milik Bappebti maupun swasta. Pada 2024, nilai transaksi SRG mencapai Rp2,866 triliun (naik 202,64%), dan pembiayaan Rp1,892 triliun (naik 199,36%). Kementerian Perdagangan telah menyetujui 22 komoditas untuk disimpan di gudang SRG, termasuk beras, gabah, gula, kedelai, dan bawang merah, yang berperan dalam stabilisasi harga. Serta kopi, rumput laut, ikan, dan timah menjadi prioritas untuk mendukung ekspor[7]. Meski demikian, implementasi SRG masih menghadapi berbagai tantangan, seperti terbatasnya jumlah gudang penyimpanan yang beroperasi, kurangnya kesiapan gudang, keterbatasan infrastruktur, dan perbedaan karakteristik komoditas yang mempengaruhi efektivitas penyimpanan SRG[6]. Peramalan volume komoditas dalam SRG penting untuk memastikan ketersediaan ruang penyimpanan yang memadai dan mencegah kelebihan atau kekurangan kapasitas gudang. Kesiapan ini memengaruhi kelancaran operasional SRG, yang berdampak pada stabilitas harga dan ketersediaan komoditas. Keterbatasan kapasitas berisiko menghambat petani dan pelaku usaha dalam menyimpan komoditas pada waktu yang tepat. Oleh karena itu, pemantauan dan peramalan volume masuk gudang diperlukan untuk mengoptimalkan penggunaan fasilitas, menekan kerugian, dan memaksimalkan fungsi SRG. Penelitian ini membandingkan metode *Prophet*, *Exponential Smoothing*, dan SARIMA dalam meramalkan volume transaksi berdasarkan kemampuan masing-masing dalam mengolah data

Beberapa penelitian sebelumnya telah membahas peran SRG seperti [8] dan [9], yaitu sebagai instrumen pembiayaan dan peningkatan pendapatan petani melalui mekanisme tunda jual, memberikan kepastian mutu dan kuantitas komoditas, memperkuat posisi tawar petani, serta memfasilitasi akses kredit melalui Resi Gudang sebagai agunan. Selain itu, terdapat penelitian yang melakukan peramalan menggunakan metode *Exponential Smoothing*, seperti yang dijelaskan dalam [10], serta yang membandingkan metode *Exponential Smoothing* dengan SARIMA, seperti yang terdapat dalam [11], [12], dan [13]. Penelitian lain juga membandingkan metode SARIMA dengan *Prophet*, seperti yang tercantum dalam [14], dan yang membandingkan metode *Prophet*, *Exponential Smoothing*, serta SARIMA dalam [15].

Berdasarkan uraian, telah banyak dilakukan penelitian mengenai SRG dan melakukan analisis peramalan dengan menggunakan metode *Prophet*, *Exponential Smoothing*, dan SARIMA. Namun, masih terbatas penelitian yang membahas penerapan metode-metode tersebut dalam konteks SRG, khususnya dalam aspek peramalan volume transaksi yang akan memberikan wawasan bagi pengelolaan kapasitas gudang dan pengambilan kebijakan strategis. Oleh karena itu, tujuan utama penelitian ini adalah untuk membandingkan efektivitas ketiga metode tersebut dalam meramalkan volume transaksi SRG. Penelitian ini relevan dengan kebijakan pemerintah yang berfokus pada peningkatan ketahanan pangan, efisiensi logistik, serta pemberdayaan petani dan pelaku usaha. Hasil dari penelitian ini diharapkan dapat menjadi dasar bagi kebijakan yang lebih terarah dan tepat sasaran dalam mendukung pengembangan Sistem Resi Gudang, menjaga stabilitas harga, serta menjamin ketersediaan komoditas nasional.

2. Metodologi Penelitian

Penelitian ini bertujuan untuk membandingkan efektivitas tiga metode peramalan volume transaksi Sistem Resi Gudang (SRG), yaitu *Prophet*, *Exponential Smoothing*, dan SARIMA. Dalam penelitian ini, digunakan data sekunder yang diolah melalui serangkaian langkah metodologi yang terstruktur. Penelitian ini juga melibatkan pengukuran akurasi

model peramalan dengan menggunakan beberapa metrik *error*. Berikut adalah deskripsi metodologi penelitian yang digunakan

2.1. Data dan Sumber Data

Penelitian ini menggunakan data sekunder yang diperoleh dari Laporan Rekap Resi Gudang yang disediakan oleh Badan Pengawas Perdagangan Berjangka Komoditi (BAPPEBTI). Laporan ini bersifat internal dan tidak dipublikasikan secara umum. Data asli dalam laporan tersebut tidak disusun dalam bentuk deret waktu bulanan, sehingga peneliti melakukan rekapitulasi dan pengolahan untuk menghasilkan *time series* yang mencakup volume penerbitan Resi Gudang secara keseluruhan setiap bulan.

2.2. Definisi Variabel

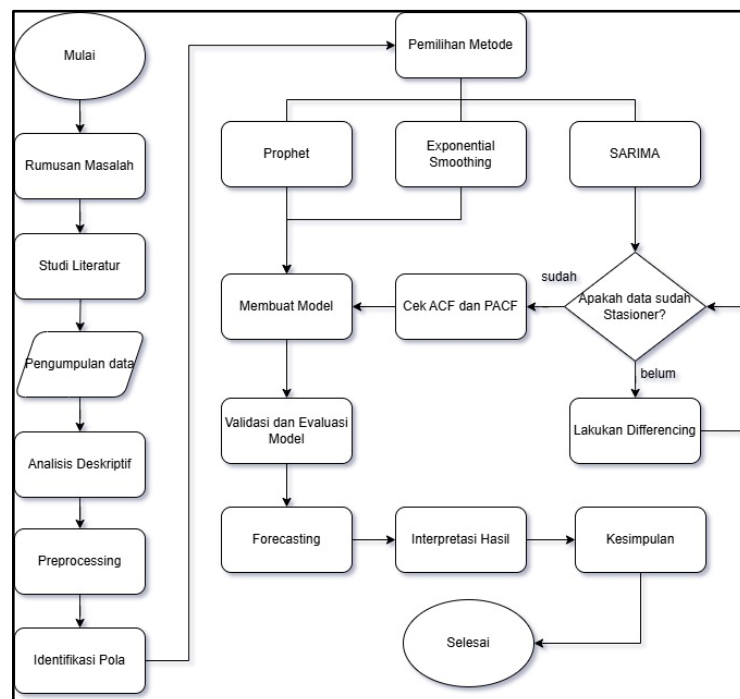
Penelitian ini menggunakan dua variabel utama, yaitu *Waktu*, yang terekam dalam satuan bulanan, dan *Volume*, yaitu jumlah komoditas yang diterbitkan melalui Sistem Resi Gudang (SRG) setiap bulan. Memiliki satuan Ton

Tabel 1 Definisi variabel

Nama Variabel	Definisi Variabel
Waktu	Periode pengamatan dalam satuan bulanan. Dimulai dari Januari 2022 hingga Desember 2024
Volume	Jumlah komoditas yang diterbitkan melalui Sistem Resi Gudang (SRG) setiap bulan. Memiliki satuan Ton

2.3. Metode Penelitian

Analisis data deret waktu akan dilakukan menggunakan pendekatan deskriptif dan metode peramalan deret waktu, yaitu *Prophet*, *Exponential Smoothing*, dan *SARIMA*. Setiap metode akan dievaluasi berdasarkan akurasi peramalan yang dihasilkan, dengan pengukuran *error* menggunakan *MASE* (*Mean Absolute Scaled Error*). Analisis yang dilakukan akan mengabaikan faktor lain yang berpengaruh. Proses analisis ini akan dilaksanakan dengan bantuan perangkat lunak Python.



Gambar 1 Diagram Alir

Berikut Langkah-langkah dalam proses analisis:

1. Perumusan Masalah & Studi Literatur

Menentukan fokus penelitian, variabel yang dianalisis, serta mempelajari teori dan metode peramalan deret waktu yang relevan.

2. Pengumpulan Data

Mengumpulkan data historis dari Laporan Rekap Resi Gudang.

3. Analisis Deskriptif, *Preprocessing*, dan Identifikasi Pola

Menganalisis karakteristik statistik data, cek *missing value*, cek *outlier*, dan memvisualisasikan deret waktu untuk mendeteksi tren, musiman, dan siklus.

4. Pemilihan & Pembuatan Model

Memilih metode peramalan (SARIMA, *Prophet*, *Exponential Smoothing*) berdasarkan pola data, lalu membangun model sesuai metode terpilih.

- Untuk SARIMA: uji stasioneritas (ADF) dan *Differencing*, analisis ACF/PACF.
- Untuk *Prophet* & *Exponential Smoothing*: langsung dimodelkan tanpa uji stasioneritas.

5. Validasi & Evaluasi Model

Membandingkan hasil prediksi dengan data aktual menggunakan metrik MASE. Model dipilih berdasarkan *error* terkecil dan bisa menangkap pola data.

6. *Forecasting* & Interpretasi Hasil

Melakukan peramalan menggunakan model terbaik dan menganalisis hasil prediksi.

7. Kesimpulan

Menyimpulkan hasil penelitian dan memberikan saran berdasarkan temuan.

a) *Prophet*

Prophet adalah model *additive* yang dirancang untuk menangani data dengan tren *non-linear*, musiman, peristiwa khusus, data hilang dan *outlier*, tren yang mendekati batas atas atau bawah secara asimtotik [16]. Berikut adalah rumus dari *Prophet*[17]:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (1)$$

Keterangan:

y = *Forecast / additive regressive model*; g = Tren pertumbuhan; s = Tren musiman; h = Efek hari libur; ε = *error*;

Dengan:

$$g(t) = \frac{C}{1 + \exp(-k(t - m))} \quad (2)$$

Keterangan:

C = Kapasitas maksimum; k = Laju pertumbuhan; m = parameter *Offset*; t = waktu; $g(t)$ = waktu ke t ;

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{p}\right) + b_n \sin\left(\frac{2\pi nt}{p}\right) \right) \quad (3)$$

Keterangan:
P = periode waktu;

$$h(t) = [1(t \in D_1), \dots, 1(t \in D_L)]\kappa \quad (4)$$

Keterangan:
D = Set dari tanggal liburan di masa lalu dan masa depan; t = Waktu saat sedang liburan;
 κ = perubahan hari libur saat prediksi.

b) *Exponential Smoothing*

Exponential Smoothing adalah metode peramalan yang menggunakan rata-rata berbobot dari data masa lalu, dengan kata lain, semakin baru data, semakin besar bobot yang diberikan dan berkurang secara eksponensial seiring bertambahnya usia observasi[18].

1. *Single Exponential Smoothing (SES)*: Metode peramalan yang memberikan bobot lebih besar pada data terbaru dan semakin kecil pada data sebelumnya. Cocok untuk data yang tidak menunjukkan tren atau musiman.
2. *Double Exponential Smoothing (Holt's Linear Trend)*: pengembangan SES dengan menambahkan komponen tren, cocok peramalan untuk data yang menunjukkan pola tren *linear*.
3. *Triple Exponential Smoothing (Holt-Winters)*: Metode peramalan yang memperhitungkan level, tren, dan musiman. Cocok untuk data yang menunjukkan pola musiman dan tren. Terdapat 2 model utama:
 - a) *Additive*: Digunakan ketika variasi musiman bersifat konstan sepanjang waktu.
 - b) *Multiplicative*: Digunakan ketika variasi musiman berubah relatif terhadap level data.

c) *SARIMA*

Seasonal Autoregressive Integrated Moving Average (SARIMA) merupakan pengembangan dari model *ARIMA* yang memperhatikan pola musiman[18]. Model *SARIMA* ditulis sebagai[14]:

$$SARIMA(p, d, q)(P, D, Q)_s$$

dengan:

p = AR non-musiman; d = *Diferensiasi* non-musiman; q = MA non-musiman; P = AR musiman; D = *Diferensiasi* musiman; Q = MA musiman; S = Rentang waktu pengulangan pola musiman, Rumus umum dari *SARIMA*[19] dijelaskan dalam persamaan (5) berikut:

$$\phi_p(B^s)\phi_p(B)(1 - B^2)^d(1 - B)^dX_t = \theta_q(B^s)\theta_q(B)Z_t. \quad (5)$$

d) *Perhitungan Nilai Error*

Dalam penelitian ini, evaluasi performa model dilakukan menggunakan *Mean Absolute Scaled Error (MASE)*. *MASE* digunakan sebagai alternatif dari *MAPE* karena kelemahan *MAPE* yaitu tidak bisa digunakan saat data aktual bernilai nol atau sangat kecil, sensitif terhadap *outlier*, dan cenderung memberi bobot lebih besar pada nilai yang tinggi[20], termasuk data yang memiliki variansi yang besar. Hal ini menyebabkan hasil *MAPE* akan memiliki nilai yang tinggi. Rumus *MASE* adalah[21]:

$$MASE = \text{mean}(|q_t|)$$

dengan:

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|} \quad (6)$$

Keterangan:

$e_t = Y_t - F_t$: Error antara nilai aktual dan prediksi; q_t = Skala kesalahan waktu ke-t; n = jumlah total observasi.

Nilai MASE yang lebih dari 1 menunjukkan model yang kurang baik, jika nilai nya sama dengan 1 maka model setara dengan *naive forecast*, jika model kurang dari 1 maka model lebih baik dari *naive forecast*[22].

3. Hasil dan Pembahasan

Pada bagian ini akan membahas hasil dari pengujian yang dilakukan pada data Volume Sistem Resi Gudang.

3.1. Analisis Deskriptif

Analisis Deskriptif digunakan untuk menganalisis Gambaran umum dari data Volume Resi Gudang yang diterbitkan.

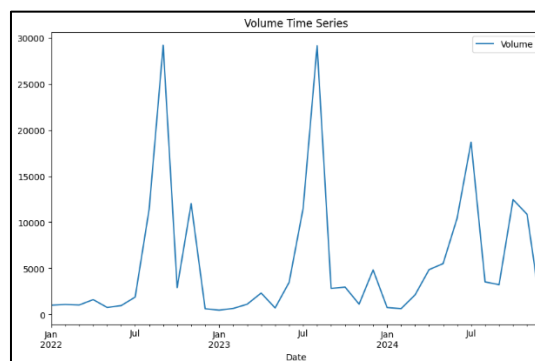
Tabel 2 Statistika Deskriptif

Min	Mean	Max	SD
389.1	5526.2	29216.3	7380.171

Data volume memiliki nilai minimum sebesar 389,1 dan maksimum sebesar 29.216,3, menunjukkan rentang yang sangat lebar. Rata-rata sebesar 5.526,2 berada jauh di atas nilai minimum dan relatif dekat ke arah maksimum, yang mengindikasikan adanya kemungkinan nilai-nilai ekstrem (*outlier*). Standar Deviasi sebesar 7380.171 menunjukkan tingkat penyebaran data yang sangat tinggi di sekitar rata-rata, yang memperkuat dugaan bahwa data tidak tersebar merata dan memiliki fluktuasi volume yang signifikan dari waktu ke waktu.

3.2. Analisis Runtun Waktu

Pada tahap awal *preprocessing*, dilakukan pengecekan terhadap data yang hilang untuk memastikan kualitas data yang digunakan dalam proses peramalan. Data yang mengandung nilai kosong dapat menyebabkan kesalahan dalam proses analisis deret waktu. Kemudian dilakukan pengecekan *outlier*.



Gambar 2 Plot deret waktu dari volume

Berdasarkan Gambar 2, terlihat adanya lonjakan yang cukup tinggi pada periode tertentu, khususnya di pertengahan tahun. Hal ini mengindikasikan adanya pola musiman

dalam data. Volume mengalami fluktuasi yang signifikan dari waktu ke waktu, yang kemungkinan besar disebabkan oleh musim panen yang menyebabkan peningkatan jumlah volume yang masuk. Secara umum, tidak terdapat tren yang konsisten secara jangka panjang, baik naik maupun turun, sehingga karakteristik data lebih condong pada pola musiman daripada tren linier. Selain itu, pola musiman belum dapat dipastikan bersifat aditif atau multiplikatif, sehingga pada tahap pemodelan akan diuji kedua pendekatan tersebut. Oleh karena itu, metode yang digunakan untuk analisis peramalan dalam penelitian ini meliputi *Prophet* yang cocok untuk data musiman dan mudah menangani outlier, *Exponential Smoothing* yang cocok untuk data musiman yang stabil, dan SARIMA yang cocok menangani data musiman dan fluktuatif pada data.

Setelah pemilihan metode peramalan dilakukan, tahap selanjutnya adalah memastikan bahwa data memenuhi syarat penggunaan metode tersebut. Khusus untuk metode SARIMA, diperlukan asumsi bahwa data telah bersifat stasioner, yaitu tidak memiliki tren atau pola yang berubah secara sistematis dari waktu ke waktu.

Pengujian stasioneritas dilakukan menggunakan *Augmented Dickey-Fuller* (ADF) Test, yang menguji apakah data stasioner pada *mean* (rata-rata). Dari uji ADF yang dilakukan dapat diperoleh hipotesis sebagai berikut.

- i. Hipotesis
 H_0 : Data tidak stasioner
 H_1 : Data stasioner
- ii. Taraf Signifikansi
 $\alpha = 0.05$
- iii. Daerah Kritis
Tolak H_0 jika $p\text{-value} < \alpha$
- iv. Statistik Uji dan Keputusan

Tabel 3 Nilai *P-value* uji ADF

	P-value ADF test	Ket.	Keputusan
Tanpa <i>Differencing</i>	0.1641	> 0.05 (tidak stasioner)	Gagal Tolak H_0
<i>Differencing</i> 1 kali	0.2406	> 0.05 (tidak stasioner)	Gagal Tolak H_0
<i>Differencing</i> 2 kali	0.01	< 0.05 (stasioner)	Tolak H_0

- v. Kesimpulan
Berdasarkan hasil pengujian stasioneritas menggunakan uji *Augmented Dickey-Fuller* (ADF), dengan tingkat kepercayaan 95% data yang ada belum stasioner pada kondisi awal (tanpa *Differencing*) dan setelah satu kali *Differencing*. Data baru menjadi stasioner setelah dilakukan dua kali *Differencing*, ditunjukkan oleh nilai $p\text{-value} < 0.05$

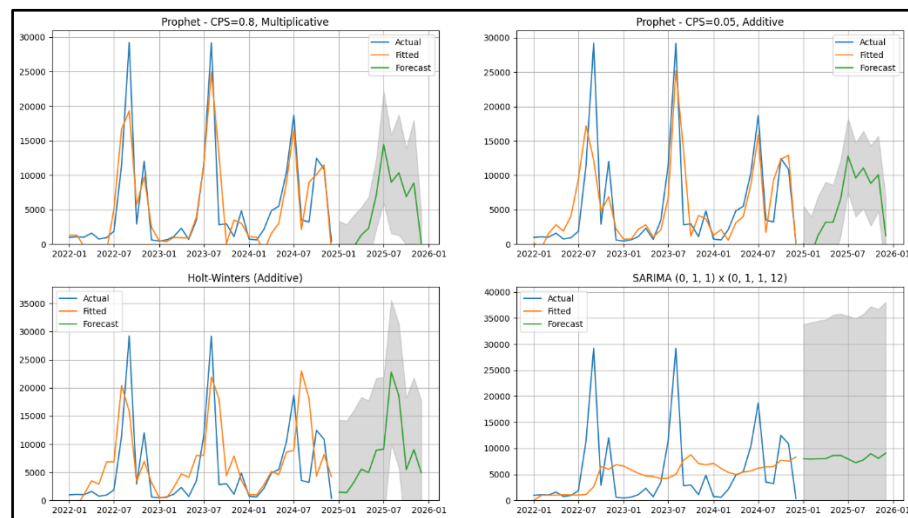
Dengan demikian, nilai *Differencing* optimal untuk memenuhi syarat penggunaan SARIMA adalah $d = 2$.

Meskipun pendekatan tradisional dalam pemodelan SARIMA sering melibatkan analisis grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) untuk menentukan nilai parameter p dan q , dalam penelitian ini digunakan pendekatan *grid search*. Metode ini secara otomatis mengevaluasi berbagai kombinasi parameter dan memilih yang terbaik berdasarkan nilai *Akaike Information Criterion* (AIC). Pendekatan ini dianggap lebih objektif dan sistematis dalam menentukan parameter, serta mengurangi potensi bias atau kesalahan subjektif dalam interpretasi grafik ACF/PACF. Diperoleh kombinasi terbaik untuk metode SARIMA adalah SARIMA(0, 1, 1) x (0, 1, 1, 12) dengan AIC 195.02.

Dalam pembuatan model dengan metode *Prophet*, meskipun *Prophet* tidak memiliki fitur *grid search* otomatis, penyesuaian parameter dilakukan dengan mencoba

beberapa kombinasi nilai *changepoint_prior_scale* (CPS) dan *seasonality_mode*, dan diperoleh hasil terbaik yaitu CPS = 0.8 dan *seasonality_mode* = 'multiplicative'. Sebagai pembandingan, akan buat juga model dengan CPS = 0.05 dan *seasonality_mode* = 'additive'.

Untuk model *Exponential Smoothing* (*Holt-Winters*), konfigurasi musiman multiplicative telah dicoba, namun hasilnya kurang memuaskan. Oleh karena itu, digunakan konfigurasi *additive* untuk komponen tren dan musiman, yang memberikan hasil prediksi lebih stabil dan sesuai dengan pola data. Periode musiman ditetapkan selama 12 bulan. Hasil visualisasi dan perbandingan model ditampilkan pada Gambar 3.



Gambar 3 Plot Forecasting

Gambar 3 menampilkan perbandingan pola prediksi dari empat model peramalan: *Prophet* (dengan dua konfigurasi), *Holt-Winters*, dan *SARIMA*. *Prophet* dengan konfigurasi *multiplicative* dan CPS(*changepoint_prior_scale*) 0.8 menunjukkan pola yang paling menyerupai data historis, dengan kemampuan menangkap lonjakan musiman secara jelas dan realistis. Sebaliknya, *Prophet* dengan konfigurasi *additive* dan CPS 0.5 menghasilkan pola prediksi yang tidak sebaik *Prophet multiplicative* dengan CPS 0.8. Model *Holt-Winters* juga menunjukkan pola yang cukup halus namun kurang responsif terhadap fluktuasi besar. Sementara itu, model *SARIMA* menghasilkan pola prediksi yang terlihat datar dan tidak banyak perubahan dari bulan ke bulan, sehingga kurang mencerminkan kondisi data sebenarnya yang sering naik turun secara tajam. Secara keseluruhan, pola musiman data lebih kompleks dan fluktuatif, sehingga *Prophet multiplicative* secara visual lebih tepat.

3.2.1. Evaluasi Nilai Error Model

Evaluasi performa model dilakukan dengan menggunakan metrik MASE (*Mean Absolute Scaled Error*) untuk membandingkan akurasi prediksi dari beberapa metode peramalan yang digunakan dalam penelitian ini.

Tabel 4 Nilai MASE

Model	MASE
<i>Prophet</i> (CPS = 0.8, <i>multiplicative</i>)	0.4134
<i>Prophet</i> (CPS = 0.05, <i>additive</i>)	0.4897
<i>Holt-Winters</i> (<i>Additive</i>)	0.7875
<i>SARIMA</i> (0,1,1) × (0,1,1,12)	0.9097

Model *Prophet* (*multiplicative*, CPS = 0.8) memiliki performa terbaik dengan nilai MASE terendah sebesar 0.4134, menandakan akurasi prediksi yang paling tinggi. Diikuti oleh *Prophet* (*additive*, CPS = 0.05) dengan MASE 0.4897. Model *Holt-Winters* memiliki

akurasi yang lebih rendah dengan MASE 0.7875, dan SARIMA menunjukkan performa terendah dengan MASE 0.9097. Seluruh model memiliki nilai MASE di bawah 1, yang berarti performa masing-masing model masih lebih baik dibandingkan model naive (model acak atau tanpa pola).

Berdasarkan hasil prediksi (*forecast*) yang ditampilkan pada Gambar 3, model *Prophet* terlihat cukup baik dalam menyesuaikan diri dengan data historis saat dilakukan *fitting* (pelatihan model). Namun, ketika digunakan untuk *Forecasting* (prediksi ke depan), model *Prophet* kurang bisa mengikuti fluktuasi tajam yang terjadi sebelumnya, sehingga hasil prediksinya tidak seakurat data yang sebenarnya. Sebaliknya, model *Exponential Smoothing (Holt-Winters)* lebih baik dalam mengikuti pola fluktuasi data di masa depan, meskipun nilai *error*-nya (MASE) lebih tinggi dibandingkan *Prophet*. Ini menunjukkan bahwa meskipun *Prophet* lebih baik dalam menyesuaikan diri dengan data historis, *Exponential Smoothing* lebih responsif terhadap perubahan mendadak dalam data ke depan. Sehingga *Forecasting* akan dilakukan menggunakan metode Model *Prophet* (multiplicative, CPS = 0.8) dan *Exponential Smoothing (Holt-Winters)*..

Tabel 5 Hasil *Forecasting*

Waktu	<i>Prophet</i> (multiplicative, CPS = 0.8)	<i>Holt-Winters</i> (Additive)
Januari 2025	-1113.75	1480.49
Februari 2025	-1246.55	1396.65
Maret 2025	-443.60	3153.69
April 2025	1336.09	5545.52
Mei 2025	2301.90	4962.28
Juni 2025	7094.99	8910.11
Juli 2025	14460.82	9110.14
Agustus 2025	8982.25	22801.26
September 2025	10344.09	18579.24
Oktober 2025	6895.8	5481.43
November 2025	8874.88	9012.68
Desember 2025	161.81	4946.30

Model *Prophet* memberikan hasil yang memiliki nilai negatif untuk tiga bulan pertama tahun 2025, yang secara logis tidak mungkin terjadi dalam konteks volume komoditas. Ini menandakan kelemahan *Prophet* dalam menangani fluktuasi ekstrem saat data historis tidak mencerminkan kejadian serupa. Model *Holt-Winters additive* memberikan hasil yang lebih realistis dan responsif terhadap pola musiman dan fluktuasi data, meskipun nilai MASE sedikit lebih tinggi dari *Prophet*. Model *Holt-Winters* memprediksi volume tertinggi terjadi pada bulan Agustus dan September 2025, sedangkan metode *Prophet* terjadi pada bulan Juli dan September 2025.

4. Kesimpulan

Dari hasil evaluasi, model *Prophet* (multiplicative, CPS = 0.8) memberikan hasil akurasi prediksi tertinggi berdasarkan nilai MASE (0.4134), menunjukkan kemampuannya menangkap pola data historis dengan baik. Namun hasil peramalan menghasilkan nilai negatif pada 3 bulan pertama yang tidak realistis dalam konteks volume transaksi SRG. Sebaliknya, metode *Exponential Smoothing (Holt-Winters)* lebih mampu menghasilkan prediksi yang stabil dan realistis meskipun dengan MASE yang lebih tinggi (0.7875). SARIMA menunjukkan performa paling rendah dengan nilai MASE tertinggi (0.9097), serta menghasilkan pola prediksi yang terlalu datar dan kurang mempresentasikan pola data sebenarnya. Dengan mempertimbangkan aspek akurasi dan realisasi pola prediksi, metode *Prophet* dan *Exponential Smoothing (Holt-Winters)* dipilih sebagai pendekatan terbaik untuk peramalan volume Sistem Resi Gudang.

Berdasarkan hasil prediksi, beberapa langkah yang bisa diambil untuk meningkatkan kinerja SRG adalah dengan mempersiapkan kapasitas gudang sebelum meningkatnya volume komoditas yang masuk, sehingga tidak perlu menambah biaya operasional yang tidak perlu. Selain itu, mengetahui volume yang masuk juga diperlukan dalam proses penerimaan barang dan pemeriksaan kualitas komoditas yang masuk, sehingga dapat mempersiapkan SDM untuk meningkatkan efisiensi. Pemantauan yang baik agar gudang tetap layak dan berfungsi dengan optimal juga sangat penting, karena hal ini berguna untuk meminimalkan risiko terjadinya hal-hal yang tidak diinginkan. Selain itu, gudang juga dipersiapkan sesuai dengan komoditas yang memiliki volume tinggi, seperti gabah, beras, gula, dan lain sebagainya, sehingga fokus utama adalah mengalokasikan kapasitas penyimpanan untuk komoditas-komoditas tersebut terlebih dahulu, guna menghindari kekurangan kapasitas dan memastikan efisiensi operasional.

5. Daftar Pustaka

- [1] Pemerintah Republik Indonesia, *UU 9 Tahun 2011*. Indonesia: LN.2011/No. 78, TLN No. 5231, LL SETNEG: 13 HLM, 2011. [Online]. Available: <https://peraturan.bpk.go.id/Home/Details/39184>
- [2] Kudagang, “Sistem Resi Gudang Menyejahterakan Petani,” Kementerian Perdagangan. [Online]. Available: <https://kudagang.kemendag.go.id/kms/materi/4fa40b3a-0d27-40c0-801e-89b6c003e2c3/preview>
- [3] Administrator, “Tantangan Besar, Asta Cita, dan Keberlanjutan Pembangunan,” Portal Informasi Indonesia.
- [4] A. Doyoharjo, “Sistem Resi Gudang sebagai Alternatif Sumber Pembiayaan untuk Komoditas Pertanian,” Surakarta, Apr. 2008.
- [5] D. Afrijal, “Pengaruh Faktor-faktor Produksi terhadap Pendapatan Petani Padi di Kecamatan Tangan-tangan Kabupaten Aceh Barat Daya,” Universitas Islam Negeri Ar-Raniry, 2021.
- [6] Ashari, “Potensi dan Kendala Sistem Resi Gudang (SRG) untuk Mendukung Pembiayaan Usaha Pertanian di Indonesia,” *Forum Penelitian Agro Ekonomi*, 2011.
- [7] Bappebti, “Capaian Bappebti Tahun Lalu Jadi Pijakan Tingkatkan Peran PBK,” Jakarta, Jan. 2025.
- [8] I. S. Anugrah, Y. H. Saputra, and Erwidodo, “Prospek Penyelenggaraan Sistem Resi Gudang (SRG) sebagai Instrumen Sumber Pembiayaan dan Peningkatan Pendapatan Petani Jagung,” *Analisis Kebijakan Pertanian*, vol. 21, no. 2, pp. 199–230, Dec. 2023.
- [9] L. Zulkarnain, “Analisis Transaksi Resi Gudang dan Potensi Pengembangannya ke Unit Syariah,” *Jurnal Ekonomi dan Perbankan Syariah*, vol. 5, Apr. 2017.
- [10] Y. Dwi Darma, N. Riska Wiyanti, and A. Gunawan, “Comparative Analysis of Arima Model and Exponential Smoothing in Predicting Inventory in Automotive Companies,” 2022, doi: 10.33258/birci.v5i1.3707.
- [11] G. A. N. Pongdatu and Y. H. Putra, “Seasonal Time Series Forecasting using SARIMA and Holt Winter’s Exponential Smoothing,” *IOP Conf Ser Mater Sci Eng*, vol. 407, no. 1, Sep. 2018, doi: 10.1088/1757-899X/407/1/012153.

- [12] Z. Mustofa, “Peramalan Permintaan Produk X Dengan Metode Sarima Dan Exponential Smoothing Holt-Winters Dalam Mengoptimalkan Manajemen Rantai Pasokan,” Universitas Brawijaya., Malang, 2022.
- [13] Kurniawan, A. Adizari, and Solimun, “Peramalan Permintaan Produk X Dengan Metode Sarima Dan Exponential Smoothing Holt-Winters Dalam Mengoptimalkan Manajemen Rantai Pasokan,” Universitas Brawijaya., Malang, 2022.
- [14] W. Gunawan and M. Ramadani, “Analisa Perbandingan Penerapan Metode SARIMA dan Prophet dalam Memprediksi Persediaan Barang PT XYZ,” *Faktor Exacta*, vol. 16, no. 2, Jul. 2023, doi: 10.30998/faktorexacta.v16i2.13803.
- [15] S. D. Purwanti, “Peramalan Penjualan Produk Merchandise CV. TOP SMART Menggunakan Model Seasonal Autoregressive Integrated Moving Average (SARIMA),” Institut Teknologi Sepuluh Nopember, Surabaya, 2024.
- [16] Greg. Rafferty, *Forecasting time series data with Prophet : build, improve, and optimize time series forecasting models using Meta’s advanced forecasting tool*. Packt Publishing Ltd., 2023.
- [17] N. Kristian Darmawan, “Prediksi Saham BSDE Menggunakan Facebook Prophet Model,” Universitas Multimedia Nusantara, Tangerang, 2021.
- [18] H. Rob J. and A. George, “Forecasting: Principles and Practice,” 3rd ed., Melbourne, Australia: OTexts, 2021.
- [19] A. Agung Dwi Ramadhan and A. Fauzan, “Prediksi Nilai Ekspor Non Migas Di Jawa Barat Menggunakan Metode Seasonal Auto Regresif Integrated Moving Average (SARIMA),” *Emerging Statistics and Data Science Journal*, vol. 1, no. 1, pp. 10–19, Jan. 2023, doi: 10.20885/esds.vol1.iss.1.art2.
- [20] H. Nuha, “Mean Absolute Percentage Error (MAPE) dan Pengertiannya.” [Online]. Available: Nuha, Hilal, Mean Absolute Percentage Error (MAPE) dan Pengertiannya (April 18, 2023). Available at SSRN: <https://ssrn.com/abstract=4422741>
- [21] Deltaningtyas Tri Cahyaningrum, “Model Ekonometrika untuk Analisis Kapasitas Penerbangan Rute Jember–Surabaya di Bandara Notohadinegoro,” Institut Teknologi Sepuluh Nopember, Surabaya, 2016.
- [22] D. Nandika, “Peramalan Jumlah Penderita Difteri Menggunakan Metode Radial Basis Function Neural Network (RBFNN),” Institut Teknologi Sepuluh November, Surabaya, 2019.