

PERBANDINGAN KINERJA MODEL ARIMA DAN *HOLT-WINTERS* DALAM MEMPREDIKSI NILAI EKSPOR INDONESIA

*R. Akbar, I W. Mangku, dan B. P. Silalahi

Program Studi Matematika, Sekolah Sains Data, Matematika, dan Informatika,
Institut Pertanian Bogor, Jl. Meranti, Kampus IPB Dramaga Bogor.

akbarraihan@apps.ipb.ac.id*corresponding author,
wayanma@apps.ipb.ac.id, bibsi@apps.ipb.ac.id

Abstrak

Ekspor merupakan kegiatan pengiriman dan penjualan barang atau jasa yang diproduksi dari dalam negeri ke luar negeri. Nilai ekspor Indonesia meningkat pesat beberapa tahun belakangan untuk semua komoditi namun bersifat fluktuatif. Guna memperkirakan nilai ekspor Indonesia selanjutnya digunakan model *Autoregressive Integrated Moving Average* (ARIMA) dan *Holt-Winters* yang dapat membantu mengambil kebijakan. Adapun tujuan dari penelitian ini adalah membandingkan kinerja model ARIMA dan *Holt-Winters* agar mendapatkan model terbaik untuk memprediksi nilai ekspor Indonesia untuk 1 tahun ke depan. Data nilai ekspor Indonesia dibagi menjadi data training sebanyak 119 data dan data testing sebanyak 13 data dengan periode waktu Januari 2013 hingga Desember 2023. Model ARIMA(3,1,2) merupakan model terbaik dari ARIMA dengan MAPE sebesar 11.766% dan model terbaik dari *Holt-Winters* adalah *Holt-Winters Additive* dengan MAPE sebesar 5.131%. Penelitian ini menghasilkan model *Holt-Winters Additive* sebagai model terbaik. Model ini digunakan untuk memprediksi nilai ekspor Indonesia untuk tahun 2024.

Kata kunci: ARIMA, *Holt-Winters*, Nilai ekspor, Prediksi

1 Pendahuluan

Ekspor adalah suatu kegiatan pengiriman dan penjualan barang maupun jasa hasil produksi dalam negeri ke luar negeri [17]. Ekspor mempunyai pengaruh terhadap perekonomian pertumbuhan di Indonesia. Jika ekspor meningkat, maka produksi barang dan jasa juga akan meningkat karena peningkatan ekspor menunjukkan peningkatan permintaan produk dalam negeri di luar negeri. Peningkatan produksi barang dan jasa akan menyebabkan pertumbuhan perekonomian [9]. Nilai ekspor mencerminkan bukan hanya jumlah barang yang dijual ke luar negeri, tetapi juga menggambarkan kondisi harga internasional yang berlaku, sehingga dapat menunjukkan kemampuan produksi dan situasi pasar global. Dalam konteks perdagangan internasional, nilai ekspor menjadi salah satu tolok ukur utama yang digunakan untuk menilai tingkat daya saing suatu negara di pasar dunia [15]. Semakin banyak negara lain yang bergantung pada pasokan dari suatu negara, maka semakin tinggi posisi dan pengaruh negara tersebut dalam perekonomian global.

Secara makroekonomi, nilai ekspor berperan besar dalam memengaruhi neraca pembayaran dan memberikan kontribusi signifikan terhadap PDB [20]. Peningkatan nilai ekspor menunjukkan meningkatnya permintaan luar negeri serta pendapatan devisa, yang berimplikasi positif terhadap kestabilan ekonomi nasional [11], [12]. Karena itu, pemantauan nilai ekspor menjadi langkah penting dalam penyusunan kebijakan untuk memperkuat kinerja perdagangan, memperluas variasi produk ekspor, dan mengurangi risiko terhadap fluktuasi ekonomi global. Dengan kata lain, nilai ekspor bukan hanya ukuran kinerja perdagangan luar negeri, melainkan juga cerminan dari proses pertumbuhan ekonomi dan perubahan struktur ekonomi suatu negara [7].

Nilai ekspor dipengaruhi oleh berbagai faktor, baik yang bersumber dari dalam negeri maupun dari luar negeri. Di antara faktor-faktor tersebut, kapasitas produksi menjadi salah satu yang paling menentukan, karena mencerminkan kemampuan suatu negara dalam menghasilkan barang dan jasa surplus untuk dijual di pasar global. Nilai tukar juga memiliki peranan penting, sebab perubahannya dapat memengaruhi harga relatif produk ekspor di pasar internasional [10]. Secara umum, depresiasi mata uang domestik akan meningkatkan daya saing ekspor karena harga produk menjadi lebih murah bagi pembeli luar negeri, sedangkan apresiasi mata uang cenderung menekan kinerja ekspor.

Berbagai penelitian di bidang ekonomi internasional menunjukkan adanya keterkaitan antara volatilitas nilai tukar dan arus perdagangan [18], [4]. Selain itu, permintaan global juga turut menentukan besarnya nilai ekspor. Misalnya, ketika negara-negara mitra dagang utama mengalami pertumbuhan ekonomi, hal ini biasanya diikuti oleh meningkatnya permintaan terhadap produk ekspor, yang pada akhirnya mendorong kenaikan nilai ekspor [22]. Bagi negara yang ekonominya bergantung pada sumber daya alam, harga komoditas menjadi faktor yang sangat krusial. Negara pengekspor komoditas utama seperti minyak, gas, atau hasil pertanian sering kali menghadapi fluktuasi nilai ekspor akibat ketidakstabilan harga komoditas tersebut [21]. Dari sisi kebijakan, aturan perdagangan dan kualitas kelembagaan berpengaruh besar terhadap performa ekspor. Kebijakan seperti penurunan tarif, penyederhanaan prosedur kepabeanan, dan peningkatan fasilitas perdagangan dapat memperkuat daya saing ekspor. Sebaliknya, hambatan perdagangan yang tinggi atau birokrasi yang tidak efisien dapat menghambat peningkatan nilai ekspor [16]. Selain itu, kualitas infrastruktur termasuk pelabuhan, sistem logistik, dan jaringan digital memiliki peran penting dalam menentukan efektivitas dan efisiensi arus perdagangan suatu negara.

Menurut data pada Badan Pusat Statistik, peningkatan ekspor terbesar terjadi pada tahun 2009 hingga 2011 dengan 40% peningkatan dari tahun sebelumnya. Pertumbuhan ekonomi melambat dari tahun 2011 menuju 2016 dengan rata-rata penurunan sebesar 5,32% [3]. Oleh karena itu, diperlukan suatu proyeksi nilai ekspor di masa depan sehingga dapat membantu pemerintah Indonesia dalam mengambil kebijakan terkait nilai ekspor. Nilai ekspor dapat diprediksi oleh metode-metode prediksi deret waktu (time series) seperti Autoregressive Integrated Moving Average (ARIMA) dan *Holt-Winters*.

ARIMA adalah model prediksi yang menggabungkan komponen *Autoregressive* (AR), *differencing/Integrating* (I), *Moving Average* (MA) yang berguna untuk prediksi data deret waktu dengan pola non-stasioner [8]. Sedangkan, *Holt-Winters* yaitu sebuah metode yang menggunakan tiga parameter *smoothing* yaitu *level*, *trend* dan *seasonal* dengan bobot pada setiap parameternya untuk memperkirakan nilai ekspor pada jangka waktu pendek berikutnya [19]. Berbeda dengan ARIMA yang mengacu pada data yang harus mengikuti distribusi probabilitas, *Holt-Winters* berbasis pada perhitungan

parameter *smoothing* tanpa asumsi probabilistik. Kedua model ini telah banyak digunakan peneliti untuk memprediksi data deret waktu.

Prediksi yang dilakukan Pires dan Martins menggunakan metode klasik ARIMA dan *Holt-Winters* serta metode modern seperti LSTM dan *Prophet* menunjukkan bahwa metode klasik sesuai untuk prediksi jangka menengah pada data deret waktu, sedangkan metode modern khususnya pada LSTM mampu memprediksi jangka panjang dengan baik [13]. Pratama *et al.* 2022 juga telah memprediksi nilai ekspor dan impor Indonesia menggunakan *Moving Average* dan *Exponential Smoothing* yang merupakan dasar dari metode ARIMA dan *Holt-Winters* dengan data nilai ekspor dan impor di tahun 2020 [14]. Hasil dari penelitian ini menghasilkan model terbaik *Exponential Smoothing* untuk nilai ekspor dengan *Mean Absolute Percentage Error* (MAPE) 8.17% dan model terbaik *Moving Average* untuk nilai impor dengan MAPE 7.12%. Erlina dan Azhar melakukan penelitian untuk memprediksi data ekspor pada komoditas kopi Indonesia yang memberikan model ARIMA(1,3,1) sebagai model dengan tingkat signifikansi < 0.0001 sehingga sesuai untuk memprediksi data tersebut [6]. Ahmar *et al.* membandingkan ARIMA, SutteARIMA, *Holt-Winters* dan NNAR dalam memprediksi bahan pangan di India dan menyimpulkan bahwa *Holt-Winters* dan SutteARIMA menghasilkan model yang lebih baik dibandingkan model lainnya bahkan *machine learning* yaitu NNAR [1]. Maka dari itu, tujuan penelitian ini adalah membandingkan kinerja model ARIMA dan *Holt-Winters* berdasarkan metrik evaluasi MAPE dalam memprediksi nilai ekspor Indonesia.

Penelitian ini memfokuskan pada penggunaan model statistik klasik dengan pertimbangan aspek praktis dan efektivitasnya dalam prediksi jangka pendek. Meskipun data pascapandemi menunjukkan volatilitas tinggi, model ARIMA dan *Holt-Winters* dipilih karena kemampuannya dalam menangkap pola secara cepat tanpa memerlukan komputasi yang kompleks. Pendekatan ini menawarkan solusi yang lebih aplikatif bagi para praktisi di lapangan, di mana kemudahan interpretasi model dan kecepatan dalam menghasilkan proyeksi jangka pendek menjadi lebih krusial dibandingkan kompleksitas algoritma. Meskipun ARIMA yang digunakan bertipe *non-seasonal*, perbandingan ini diposisikan sebagai studi benchmarking untuk melihat apakah kompleksitas struktural dalam *Holt-Winters* memberikan keunggulan akurasi yang signifikan dibandingkan kesederhanaan model ARIMA dalam menghadapi dinamika ekspor yang tidak stabil. Oleh karena itu, studi ini bertujuan memberikan instrumen peramalan yang efisien namun tetap akurat untuk mendukung pengambilan keputusan segera di tengah ketidakpastian pasar.

2 Metode Penelitian

2.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data nilai ekspor Indonesia dalam rentang waktu Januari 2013 hingga Desember 2023 dengan total 132 data yang berasal dari Badan Pusat Statistik (BPS). Data nilai ekspor dapat diakses dan diperoleh dari laman resmi BPS www.bps.go.id/id. Pada awalnya, data nilai ekspor Indonesia terpisah secara tahunan dan diintegrasikan menggunakan perangkat lunak *Microsoft Excel* untuk dapat dilakukan proses selanjutnya. Data yang sudah diintegrasikan dianalisis menggunakan model ARIMA dan *Holt-Winters* serta dilakukan prediksi nilai ekspor Indonesia dari model terbaik yang telah didapatkan menggunakan bahasa pemrograman R dalam IDE (*Integrated Development Environment*) RStudio.

2.2 ARIMA

Model ARIMA merupakan suatu model yang berguna dalam analisis dan prediksi data deret waktu (*time series*). Model ARIMA yang dibuat oleh George E.P.Box dan Gwilym M.Jenkins pada tahun 1970 telah banyak menyelesaikan permasalahan dalam kehidupan seperti prediksi di bidang ekonomi, pemasaran, produksi industri, sosial dan lain-lain. Keunggulan dari model ARIMA adalah prediksi jangka pendek yang akurat untuk deret waktu x_1, x_2, \dots, x_n . Sebuah deret waktu $\{Y_t\}$ merupakan suatu ARIMA jika pembedaan ke- d yaitu $W_t = \nabla^d Y_t$ stasioner pada proses ARMA. Jika $\{W_t\}$ merupakan suatu model ARMA(p, q), maka $\{Y_t\}$ adalah suatu proses ARIMA(p, d, q) [5]. Model ARIMA dapat dituliskan sebagai berikut.

$$W_t = c + \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (1)$$

atau dapat dinyatakan dalam notasi *backshift*

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d y_t = c + (1 + \theta_1 B + \dots + \theta_q B^q) \varepsilon_t \quad (2)$$

dengan W_t adalah deret pembedaan, c adalah *drift*, prediktornya adalah nilai *lag* y_t dan *lag error*, p adalah orde AR, d adalah derajat *differencing*, q adalah orde MA, $W_t = (1 - B)^d y_t$ [8].

2.3 Holt-Winters

Metode *Holt-Winters* adalah metode peramalan dengan tiga *parameter smoothing* yaitu α untuk *Level* (L_t), β untuk *Trend* (b_t) dan γ untuk *Seasonal* (S_t). Model ini pada awalnya dikembangkan oleh Charles C. Holt pada studinya yang berawal dari satu parameter yaitu untuk *level* saja. Selain itu, model ini memiliki dua jenis yaitu model *additive* dan *multiplicative* yang dilihat dari sifat musiman data deret waktu. Model *Holt-Winters additive* digunakan untuk data musiman yang konstan sedangkan *multiplicative* digunakan untuk data yang dipengaruhi oleh komponen *level*. Formulasi matematis untuk *Holt-Winters* yang dibagi menjadi *level*, *trend*, *seasonal* dan *forecast* adalah sebagai berikut.

Holt-Winters Additive

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (4)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (5)$$

$$F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (6)$$

Holt-Winters Multiplicative

$$L_t = \alpha \left(\frac{Y_t}{S_{t-s}} \right) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (7)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (8)$$

$$S_t = \gamma \left(\frac{Y_t}{L_t} \right) + (1 - \gamma)S_{t-s} \quad (9)$$

$$F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (10)$$

dengan Y_t adalah data pada waktu t . Selain itu, α, β , dan γ berturut-turut adalah parameter *level*, *trend*, *seasonal* bernilai $0 \leq \alpha, \beta, \gamma \leq 1$. L_t, b_t dan S_t adalah *level*, *trend* dan *seasonal* pada waktu t .

Dalam melakukan prediksi menggunakan dengan formula tersebut dibutuhkan nilai awal untuk ketiga parameternya. Nilai awal untuk *Holt-Winters Additive* dan *Holt-Winters Multiplicative* adalah sebagai berikut.

$$L_p = \frac{X_1 + \dots + X_p}{p} \quad (11)$$

$$\text{Holt-Winters Additive} : S_p = X_p - L_p \quad (12)$$

$$\text{Holt-Winters Multiplicative} : S_p = \frac{X_p}{L_p} \quad (12)$$

$$b_p = \frac{1}{p} \left(\frac{x_{p+1} - x_1}{p} + \frac{x_{p+2} - x_2}{p} + \dots + \frac{x_{p+p} - x_p}{p} \right) \quad (13)$$

2.4 Tahapan Penelitian

Penelitian ini membandingkan ARIMA dan *Holt-Winters* sebagai model terbaik untuk prediksi nilai ekspor Indonesia. Metode untuk kedua model tersebut disajikan sebagai berikut.

Langkah ARIMA:

1. Uji stasioneritas data dengan uji *Augmented Dickey-Fuller* (ADF) dengan hipotesis nol adalah data tidak stasioner dan hipotesis alternatif adalah stasioner pada data latih.
2. Jika data sudah stasioner dan linear maka lanjutkan langkah 3, namun jika belum stasioner dapat dilakukan *differencing* kemudian ulang langkah 1.
3. Tentukan orde ARIMA menggunakan plot *autocorrelation function* (ACF), *partial autocorrelation function* (PACF) dan *extended autocorrelation function* (EACF) untuk variasi model
4. Pilih model ARIMA terbaik berdasarkan nilai *Akaike's Information Criterion* (AIC) yang terkecil
5. Periksa model *overfitting* dari model terbaik yang sudah ditemukan
6. Uji asumsi-asumsi residu pada model ARIMA terbaik
7. Model terbaik ARIMA adalah model yang memenuhi asumsi residu dan memiliki AIC terkecil.

Langkah *Holt-Winters*:

1. Tentukan nilai awal untuk *level*, *trend* dan *seasonal* menggunakan persamaan (11)-(13).
2. Buat prediksi menggunakan persamaan (3)-(6) untuk *Holt-Winters Additive* dan (7)-(10) untuk *Holt-Winters Multiplicative* dengan α , β , dan γ sembarang
3. Setelah prediksi dibuat, atur nilai parameter sehingga hasil dari prediksi optimal dengan data aktual menggunakan *grid search* dengan langkah 0.1
4. Model terbaik *Holt-Winters* diukur berdasarkan nilai MAPE yang terkecil antara *Holt-Winters Additive* dan *Holt-Winters Multiplicative*.

Model terbaik yang dihasilkan ARIMA dan *Holt-Winters* kemudian dibandingkan dengan MAPE. Model dengan nilai MAPE terkecil digunakan untuk prediksi nilai ekspor Indonesia 1 tahun selanjutnya. Formulasi dari MAPE adalah sebagai berikut.

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \quad (14)$$


dengan n adalah banyak data, y_t adalah data aktual pada waktu t , \hat{y}_t adalah data prediksi untuk waktu t .

3 Hasil dan Pembahasan

3.1 Eksplorasi Data

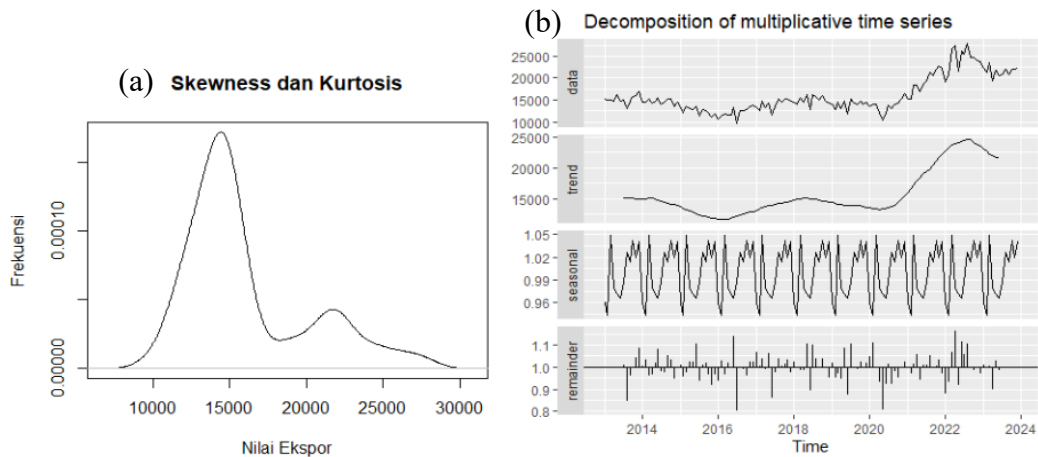
Data deret waktu dapat diidentifikasi secara ringkas melalui eksplorasi data untuk memahami pola dan karakteristik data yang digunakan dalam penelitian ini. Analisis statistika deskriptif dilakukan untuk memahami data nilai ekspor Indonesia yang selanjutnya dilakukan olah data.

Data nilai ekspor Indonesia yang digunakan sebanyak 132 data secara bulanan dengan periode Januari 2013 hingga Desember 2023 dengan nilai ekspor terendah adalah 9649.5 Juta USD pada Juli 2016 dan nilai data tertinggi adalah 27929 Juta USD pada Agustus 2022. Nilai median dari data nilai ekspor Indonesia adalah 14475 Juta USD dan rata-rata nilai ekspor bernilai 16031 Juta USD. Data nilai ekspor dipartisi menjadi data latih dan data uji dengan pembagian 90% data latih dan 10% data uji. Visualisasi dari data nilai ekspor Indonesia dari tahun 2013 – 2023 disajikan dalam *boxplot* dan plot *time series* berikut.



Gambar 1(a). *Boxplot* nilai ekspor Indonesia dan Gambar 1(b) Plot pemisahan data latih dan data uji

Berdasarkan gambar 1(a), ada beberapa pencilan karena kenaikan tidak wajar pada data nilai ekspor sekitar tahun 2021-2022. Hal ini disebabkan karena kondisi nilai ekspor yang tidak stabil pasca pandemi [2]. Pembagian data dengan skala 90:10 ini didasarkan pada data latih sebaiknya mencakup lonjakan tajam pada periode pasca pandemi tersebut agar menghasilkan model prediksi yang lebih baik. Guna memahami data lebih lanjut, plot kepekatan data berguna untuk memahami pola *skewness* dan *kurtosis* data serta dekomposisi data.



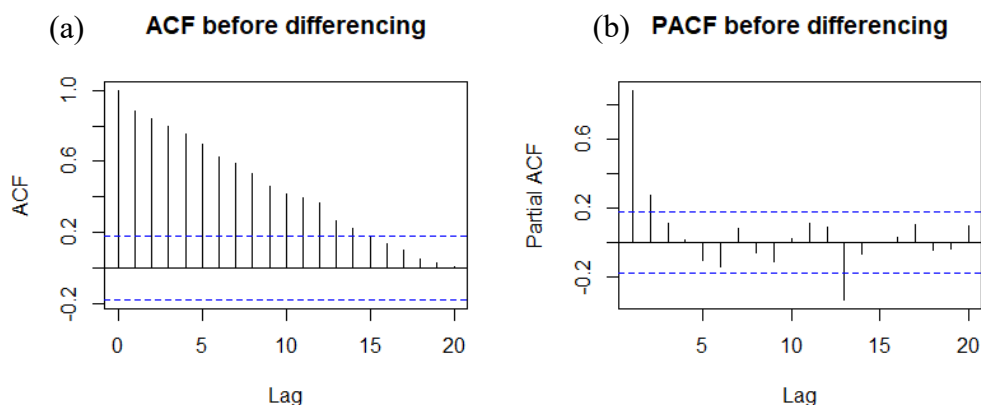
Gambar 2(a). Plot kepekatan data dan Gambar 2(b). Plot dekomposisi multiplikatif.

Nilai *skewness* sebesar 1.131 atau lebih besar dari nol yang menunjukkan bahwa distribusi data cenderung menjulur ke kanan (*positively skewed*). Hal ini berarti terdapat beberapa nilai ekspor yang jauh lebih besar daripada mayoritas nilai ekspor lainnya. *Kurtosis* ($\kappa - 3$) dari nilai ekspor Indonesia sebesar 0.413 atau lebih dari 0 yang menunjukkan bahwa distribusi data memiliki puncak yang lebih tajam dan ekor yang lebih panjang, artinya terdapat beberapa data pencilan daripada distribusi normal atau disebut juga *leptokurtic*. Selain itu, karena terlihat variasi pada pola musimannya proporsional dengan *level time series* maka dekomposisi yang lebih sesuai adalah dekomposisi multiplikatif. Dekomposisi memisahkan data *time series* menjadi empat komponen yaitu *data*, *trend*, *seasonal* dan *remainder*. Terlihat dari Gambar 2(b) bahwa terdapat *trend* yang stabil di awal dan mengalami lonjakan *trend* positif pada 2021-2022. Komponen *seasonal* juga menandakan pola musiman yang kecil dan komponen *remainder* memberikan variasi tidak biasa dari data yaitu variasinya besar ketika mengalami lonjakan tajam.

Berdasarkan dekomposisi multiplikatif juga belum terlihat jelas pola musimannya sehingga prediksi nilai ekspor lebih sesuai dengan model ARIMA tanpa *seasonal*. Hal ini dibuktikan dengan uji Kruskal-Wallis dengan kondisi jika *p-value* rendah memberikan bukti ada perbedaan yang signifikan antar kelompok, artinya terdapat keberadaan pola musiman. Namun, ketika *p-value* besar memberikan pola musiman lemah sehingga hasil prediksi ARIMA lebih baik dibandingkan SARIMA. Hasil dari uji Kruskal Wallis memberikan *p-value* = 0.8873 > 0.05 artinya pola musiman lemah dan ARIMA lebih sesuai untuk digunakan sebagai model prediksi nilai ekspor.

3.2 Model ARIMA

Stasioneritas data latih diuji menggunakan uji ADF dan dihasilkan *p-value* sebesar 0.9833 yang artinya tak tolak H_0 atau data belum stasioner. Selain itu, plot ACF dan PACF dari data latih juga belum menunjukkan orde dan ciri-ciri yang jelas untuk model ARIMA.




Gambar 3(a). Plot ACF data latih sebelum *differencing* dan Gambar 3(b). Plot PACF data uji sebelum *differencing*.

Tabel 1. Karakteristik dari ACF dan PACF terhadap model.

Plot	AR(p)	MA(q)	ARMA(p, q)
ACF	Menurun perlahan	Drop cepat menuju nol setelah <i>lag q</i>	Menurun perlahan
PACF	Drop cepat menuju nol setelah <i>lag p</i>	Menurun perlahan	Menurun perlahan

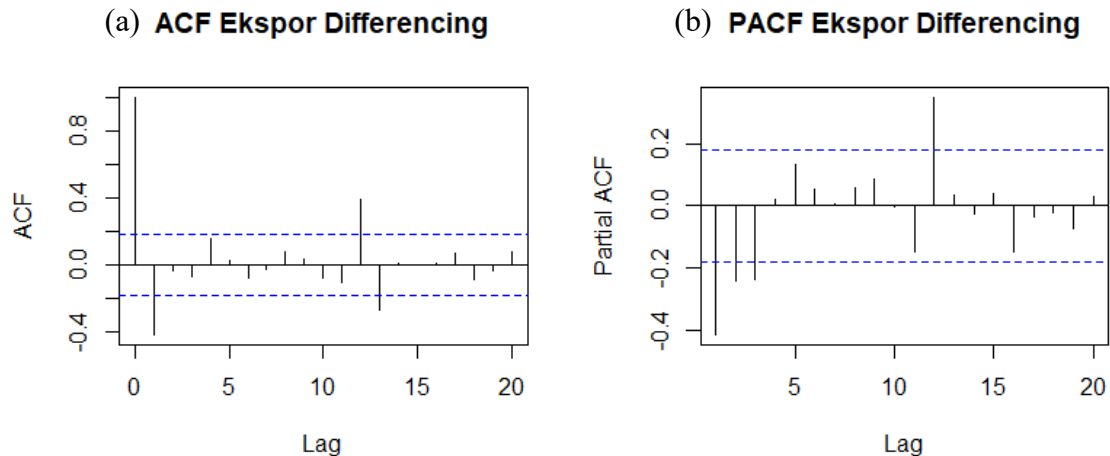
Berdasarkan plot ACF dan PACF tersebut, nilai *lag* pada plot ACF menurun perlahan artinya data belum stasioner dan belum dapat ditentukan orde ARIMA. Hal yang dapat dilakukan adalah *differencing* pada data non-stasioner untuk mengubah data menjadi stasioner. Selain itu, tabel karakteristik tersebut memberikan cara penentuan orde ARIMA dengan melihat pola plot ACF dan PACF. Grafik dari hasil *differencing* pada *lag* pertama data latih disajikan sebagai berikut.



Gambar 4. Plot hasil *differencing* data latih.

Berdasarkan Gambar 4, *differencing* sekali pada data latih telah menunjukkan pola stasioner karena menyebar di sekitar nol dari tahun 2013 hingga akhir 2022. Stasioneritas

data nilai ekspor Indonesia juga dibuktikan oleh uji ADF pada data yang telah didiferensiasi dengan hasil p -value sebesar $0,01 < 0,05$, yang menunjukkan bahwa data tersebut stasioner dan dapat dilanjutkan untuk prediksi model ARIMA. Kemudian, mengacu pada tabel 1, ACF dan PACF pun menunjukkan pola stasioner dari ACF nya yang menurun ke nol cukup cepat.



Gambar 5(a). Plot ACF setelah *differencing* dan Gambar 5(b). Plot PACF setelah *differencing*.

Berdasarkan plot tersebut, data sudah stasioner dan dapat ditentukan orde ARIMA yang sesuai. Selain itu, terlihat bahwa PACF menurun drastis atau menuju nol setelah *lag* ke-3 artinya $p = 3$ dan juga dari ACF terlihat menuju nol setelah *lag* ke 2 artinya $q = 2$. Sehingga, model ARIMA awal adalah ARIMA(3,1,2). Selanjutnya, variasi model lain juga diperiksa sebagai perbandingan model awal ini dengan plot EACF sebagai berikut.

AR/MA											
	0	1	2	3	4	5	6	7	8	9	10
0	x	o	o	o	o	o	o	o	o	o	o
1	x	o	o	o	o	o	o	o	o	o	o
2	x	x	o	o	o	o	o	o	o	o	o
3	o	x	o	o	o	o	o	o	o	o	o
4	o	x	o	o	o	o	o	o	o	o	o
5	x	x	o	o	o	o	o	o	o	o	o
6	o	x	x	o	o	o	o	o	o	o	o
7	o	o	x	o	o	o	o	o	o	o	o

Gambar 6. Hasil plot EACF untuk data latih setelah *differencing*.

Plot EACF memberikan variasi model yang mungkin untuk data latih yang ditandai dengan simbol (o). Sumbu horizontal menandakan orde untuk MA (q) dan sumbu vertikal menandakan orde untuk AR (p). Model-model tentatif yang dipilih berdasarkan plot EACF tersebut adalah ARIMA(0,1,1), ARIMA(0,1,2), ARIMA(0,1,3), ARIMA(1,1,1), ARIMA(1,1,2), ARIMA(1,1,3), ARIMA(2,1,2), ARIMA(2,1,3), ARIMA(3,1,0), ARIMA(3,1,2), dan ARIMA(3,1,3).

Selanjutnya, model-model tersebut akan dilakukan estimasi parameter, pemeriksaan parameter yang signifikan ditandai dengan nilai p -value dibawah 0.05, dan nilai AIC dari setiap model. Model yang terbaik adalah model yang memenuhi kriteria-

kriteria tersebut. Melalui RStudio dihasilkan komponen-komponen model yang disajikan dalam bentuk tabel berikut.

Tabel 2. Ringkasan Model.

Model	Parameter	Koefisien	<i>p-value</i>	AIC
ARIMA(0,1,1)	MA(1)	-0.520	1.782E-14*	2056.138
ARIMA(0,1,2)	MA(1)	-0.556	8.203E-08*	2057.903
	MA(2)	0.044	0.6318	
ARIMA(0,1,3)	MA(1)	-0.605	8.11E-11*	2057.272
	MA(2)	0.002	0.985	
	MA(3)	0.145	0.092*	
ARIMA(1,1,1)	AR(1)	-0.056	0.6886	2057.981
	MA(1)	-0.487	9.888E-06*	
ARIMA(1,1,2)	AR(1)	0.909	<2.2e-16*	2053.722
	MA(1)	-1.575	<2.2e-16*	
	MA(2)	0.658	2.279e-13*	
	AR(1)	0.902	<2.2e-16*	
ARIMA(1,1,3)	MA(1)	-1.517	<2.2e-16*	2054.686
	MA(2)	0.509	0.002*	
	MA(3)	0.100	0.297	
	AR(1)	0.476	0.029*	
ARIMA(2,1,2)	AR(2)	-0.319	0.096	2057.1
	MA(1)	-1.040	0.000*	
	MA(2)	0.532	0.002*	
	AR(1)	1.826	<2.2e-16*	
ARIMA(2,1,3)	AR(2)	-0.862	<2.2e-16*	2052.627
	MA(1)	-2.518	<2.2e-16*	
	MA(2)	2.128	1.06e-10*	
	MA(3)	-0.583	0.000*	
	AR(1)	-0.564	3.15E-10*	
ARIMA(3,1,0)	AR(2)	-0.355	0.000*	2055.636
	AR(3)	-0.235	0.009*	
	AR(1)	-0.566	1.21e-12*	
ARIMA(3,1,2)	AR(2)	-1.015	2.20e-16*	2053.704
	AR(3)	-0.517	1.11e-10*	
	MA(1)	0.121	2.60e-09*	
	MA(2)	1.000	2.20e-16*	
ARIMA(3,1,3)	AR(1)	-0.412	0.146	2059.017
	AR(2)	0.010	0.968	
	AR(3)	-0.404	0.008*	
	MA(1)	-0.151	0.580	
	MA(2)	-0.270	0.227	
	MA(3)	0.470	0.013*	

Berdasarkan Tabel 2, estimasi parameter dilakukan untuk setiap model dan diperiksa tingkat signifikansi berdasarkan nilai *p-value* dari masing-masing parameter yang ditandai dengan (*) jika signifikan. Terlihat bahwa ARIMA(2,1,3) dan

ARIMA(3,1,2) menjadi model dengan signifikansi parameter yang sangat baik yaitu semua parameternya signifikan dan modelnya cukup kompleks atau tidak terlalu sederhana. Kemudian, berdasarkan nilai AIC model ARIMA(2,1,3) memiliki nilai AIC terkecil dibandingkan ARIMA(3,1,2). Kedua model ini selanjutnya diperiksa asumsi residualnya.

Terdapat 4 asumsi yang sebaiknya dipenuhi oleh model ARIMA yaitu residual menyebar normal, *white noise*, nilai rata-rata nol dan tidak ada heteroskedastis. Uji yang digunakan guna memenuhi asumsi-asumsi tersebut berturut-turut adalah uji Kolmogorov-Smirnov, uji Ljung-Box, uji t, dan uji Breusch-Pagan. Semua uji ini harus dipenuhi dengan menolak hipotesis nol atau *p-value* lebih besar atau sama dengan 0.05. Uji asumsi-asumsi untuk kedua model disajikan dalam tabel berikut.

Tabel 3. *p-value* uji asumsi residu.

Model	Kolmogorov-Smirnov	Ljung-Box	Uji t	Breusch-Pagan
ARIMA(2,1,3)	0.434	0.946	0.469	0.000
ARIMA(3,1,2)	0.902	0.232	0.380	0.050

Berdasarkan uji asumsi residu, ARIMA(2,1,3) hanya memenuhi 3 asumsi saja walaupun memiliki parameter dan AIC terbaik dibandingkan ARIMA(3,1,2). Sedangkan ARIMA(3,1,2) memenuhi semua asumsi residu sehingga model ARIMA(3,1,2) dipilih sebagai model terbaik untuk data latih nilai ekspor Indonesia. Guna memastikan model ARIMA(3,1,2) adalah yang terbaik maka dilakukan estimasi parameter untuk model *overfitting* dengan cara menambah orde $q + 1$ atau menjadi ARIMA(3,1,3).

Tabel 4. Ringkasan model *overfitting*.

Model	Parameter	Koefisien	<i>p-value</i>	AIC
ARIMA(3,1,2)	AR(1)	-0.566	1.21e-12*	2053.704
	AR(2)	-1.015	2.20e-16*	
	AR(3)	-0.517	1.11e-10*	
	MA(1)	0.121	2.60e-09*	
	MA(2)	1.000	2.20e-16*	
	AR(1)	-0.412	0.146	
ARIMA(3,1,3)	AR(2)	0.010	0.968	2059.017
	AR(3)	-0.404	0.008*	
	MA(1)	-0.151	0.580	
	MA(2)	-0.270	0.227	
	MA(3)	0.470	0.013*	

Berdasarkan Tabel 4, dapat dilihat bahwa model *overfit* memiliki banyak parameter yang tidak signifikan dan AIC yang lebih besar daripada ARIMA(3,1,2). Hal ini menunjukkan model ARIMA(3,1,2) adalah model terbaik yang sebenarnya dan sesuai dengan model awal berdasarkan plot ACF dan PACF hasil *differencing*. Persamaan ARIMA(3,1,2) dapat dituliskan sebagai berikut.

$$(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3)(1 - B)^1 y_t = (1 + \theta_1 B + \theta_2 B^2) \varepsilon_t \quad (14)$$

atau dapat dituliskan dalam persamaan beda

$$W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \phi_3 W_{t-3} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} \quad (15)$$

$$W_t = -0.566W_{t-1} - 1.015W_{t-2} - 0.517W_{t-3} + \varepsilon_t + 0.121\varepsilon_{t-1} + \varepsilon_{t-2} \quad (16)$$

3.3 Model *Holt-Winters*

Data nilai ekspor berupa nilai ekspor bulanan yang disajikan per tahun oleh BPS sehingga periode yang sesuai untuk *Holt-Winters* adalah $p = 12$. Langkah pertama yang dilakukan adalah menentukan nilai awal untuk *level*, *trend* dan *seasonal* menggunakan formula (11)-(13) pada 12 data pertama karena $p = 12$. Guna meringkas penamaan, *Holt-Winters Additive* dinamai sebagai HWA dan *Holt-Winters Multiplicative* dinamai sebagai HWM. Berikut disajikan nilai awal untuk prediksi *Holt-Winters*.

Tabel 5. Nilai awal *Holt-Winters* untuk *level*, *trend* dan *seasonal* pada 12 data pertama.

Bulan	Level (L_p)	Trend (b_p)	HWA Seasonal (S_p)	HWM Seasonal (S_p)
Januari 2013	15212.66	-45.638	162.842	1.011
Februari 2013			-197.058	0.987
Maret 2013			-188.058	0.988
April 2013			-451.758	0.970
Mei 2013			920.742	1.061
Juni 2013			-453.858	0.970
Juli 2013			-124.758	0.992
Agustus 2013			-2128.958	0.860
September 2013			-505.858	0.967
Oktober 2013			485.642	1.032
November 2013			725.942	1.048
Desember 2013			1755.142	1.115

Tabel 5 menunjukkan periode awal dari Januari 2013-Desember 2013 menjadi dasar untuk melakukan prediksi periode selanjutnya. Nilai awal *level* dan *trend* memiliki persamaan yang sama sehingga perbedaan nilai awal hanya terjadi pada nilai awal *seasonal*. Selanjutnya, prediksi dilakukan dengan sembarang parameter *smoothing* untuk dioptimalkan menggunakan optimasi *grid search*. Optimasi *grid search* dilakukan dengan memilih nilai parameter *smoothing* α, β dan γ diantara 0 sampai 1 selangkah demi selangkah. Langkah yang digunakan untuk pencarian parameter terbaik berdasarkan nilai MAPE adalah 0.1 untuk setiap parameter sehingga total kemungkinan kombinasi parameter *smoothing* adalah 10^3 . Hasil dari optimasi *grid search* untuk parameter *smoothing* adalah sebagai berikut.

Tabel 6. Parameter dan formula prediksi untuk *Holt-Winters*

Model	α	β	γ	Formula
HWA	0.9	0.2	0.5	$L_t = 0.9(Y_t - S_{t-12}) + 0.1(L_{t-1} + b_{t-1}),$
				$b_t = 0.2(L_t - L_{t-1}) + 0.8 b_{t-1},$
				$S_t = 0.5(Y_t - L_t) + 0.5S_{t-12},$
				$F_{t+m} = L_t + b_t m + S_{t-12+m}$
HWM	0.8	0.2	0.4	$L_t = 0.8 \left(\frac{Y_t}{S_{t-12}} \right) + 0.2(L_{t-1} + b_{t-1}),$
				$b_t = 0.2(L_t - L_{t-1}) + 0.8 b_{t-1},$
				$S_t = 0.4 \left(\frac{Y_t}{L_t} \right) + 0.6 S_{t-s},$
				$F_{t+m} = (L_t + b_t m)S_{t-12+m}$

Berdasarkan hasil *grid search*, parameter *level*, *trend* dan *seasonal* yaitu α , β dan γ dari kedua model tersebut digunakan untuk prediksi data selanjutnya. Prediksi data selanjutnya memerlukan *level*, *trend* dan *seasonal* untuk waktu t . Prediksi HWA dan HWM menggunakan formula tersebut disajikan dalam tabel berikut.

Tabel 7. Parameter dan formula prediksi untuk *Holt-Winters*

Bulan	T	HWA			HWM		
		L_t	b_t	S_t	L_t	b_t	S_t
Jan 2014	13	14395.214	-200.000	119.964	14488.623	-181.318	1.006
Feb 2014	14	14767.564	-85.530	-165.261	14722.382	-98.303	0.990
Mar 2014	15	15310.796	40.222	-153.127	15231.025	23.086	0.992
Apr 2014	16	14804.934	-68.994	-482.096	14834.761	-60.784	0.968
Mei 2014	17	13986.166	-218.949	879.088	14136.883	-188.203	1.056
Jun 2014	18	15653.744	158.356	-349.051	15496.431	121.348	0.980
Jul 2014	19	14405.183	-123.027	-202.920	14516.267	-98.955	0.984
Agu 2014	20	16377.718	296.085	-2012.538	16353.880	288.359	0.870
Sep 2014	21	15870.873	135.499	-550.466	15969.432	153.797	0.963
Okt 2014	22	14927.080	-80.359	425.681	15080.408	-54.767	1.025
Nov 2014	23	13021.555	-445.392	624.544	13347.361	-390.423	1.035
Des 2014	24	12670.659	-426.493	1760.391	12945.800	-392.650	1.115
...
Nov 2021	107	22418.577	575.509	437.686	22701.250	598.241	1.009
Des 2021	108	21047.618	186.215	1418.219	21166.229	171.589	1.073
Jan 2022	109	18992.641	-262.023	275.070	19245.262	-246.922	1.011
Feb 2022	110	20385.198	68.893	11.981	20229.559	-0.678	1.004
Mar 2022	111	25681.928	1114.460	614.337	24471.184	847.782	1.059
Apr 2022	112	27813.699	1317.923	-554.017	27731.243	1330.238	0.972
Mei 2022	113	21883.334	-131.735	12.648	22861.535	90.248	0.981
Jun 2022	114	25849.743	687.894	63.583	25839.954	667.883	0.995
Jul 2022	115	25502.158	480.798	28.769	25495.611	465.437	1.005
Agu 2022	116	28850.529	1054.313	-1081.139	29005.686	1074.365	0.948
Sep 2022	117	26213.820	316.108	-1244.264	27278.363	514.027	0.922
Okt 2022	118	24800.811	-29.715	21.551	25512.979	58.145	0.982
Nov 2022	119	23736.382	-236.657	380.202	24193.890	-217.302	1.003

Prediksi data latih dilakukan untuk mendapatkan L_{119} , b_{119} dan S_{119} yang dibutuhkan untuk prediksi data uji. Data latih di prediksi dengan $m = 1$ sehingga prediksi yang dihasilkan untuk data uji lebih akurat. Formula untuk prediksi data menggunakan HWA dan HWM adalah

$$\text{HWA: } F_{119+m} = 23736.382 - 236.657m + S_{119-12+m} \quad (17)$$

$$\text{HWM: } F_{119+m} = (24193.890 - 217.302m)S_{119-12+m} \quad (18)$$

Data uji memiliki 13 data maka prediksi data uji dilakukan untuk $m = 1, 2, \dots, 13$. Hasil dari prediksi data uji disajikan pada tabel berikut.

Tabel 8. Prediksi data uji nilai ekspor Indonesia

m	Waktu	Prediksi HWA	Prediksi HWM	Aktual
1	Desember 2022	24917.94	25719.03	22357.7
2	Januari 2023	23538.14	24029.51	22320.7
3	Februari 2023	23038.39	23629.60	21319.7
4	Maret 2023	23404.09	24709.49	23413.9
5	April 2023	21999.08	22470.87	19280.4
6	Mei 2023	22329.08	22459.23	21706.5
7	Juni 2023	22143.36	22562.82	20599.0
8	Juli 2023	21871.89	22570.87	20861.3
9	Agustus 2023	20525.32	21083.95	21996.3
10	September 2023	20125.54	20307.63	20744.9
11	Oktober 2023	21154.70	21420.93	22144.5
12	November 2023	21276.69	21651.95	21995.9
13	Desember 2023	22021.29	22775.00	22391.2

Data uji diprediksi dengan menggunakan persamaan prediksi HWA dan HWM. Hasil prediksi kedua model tersebut akan dibandingkan akurasi dengan model ARIMA(3,1,2) berdasarkan nilai MAPE.

3.4 Perbandingan Kinerja Model


Model terbaik dari yang sudah dihasilkan yaitu ARIMA(3,1,2), HWA dan HWM dilihat berdasarkan nilai MAPE terkecil. Berikut adalah nilai MAPE dari model-model tersebut.

Tabel 9. Akurasi model berdasarkan MAPE

Model	MAPE
ARIMA(3,1,2)	11.766%
HWA	5.131%
HWM	6.362%

Berdasarkan nilai MAPE pada Tabel 9, model HWA menunjukkan kinerja yang lebih baik dibandingkan model lainnya dalam memprediksi nilai ekspor Indonesia, sebagaimana ditunjukkan oleh nilai MAPE yang paling kecil. Model HWA dan HWM memiliki kemampuan prediksi yang sangat baik, yang ditunjukkan oleh nilai MAPE \leq

10%, sedangkan model ARIMA(3,1,2) memiliki kemampuan prediksi yang baik dengan nilai $MAPE \leq 20\%$. Oleh karena itu, model terbaik untuk memprediksi nilai ekspor Indonesia adalah model HWA. Lebih lanjut, model Holt-Winters Additive dapat digunakan untuk memprediksi nilai ekspor tahun 2024. Tingkat akurasi dari model-model tersebut juga disajikan pada grafik berikut.



Gambar 7. Plot prediksi ketiga model dan dihasilkan model HWA yang paling akurat.

3.5 Prediksi Periode Selanjutnya

Model HWA sebagai model terbaik digunakan untuk memprediksi nilai ekspor Indonesia pada periode selanjutnya yaitu dari Januari 2024 hingga Desember 2024. Sebelum melakukan prediksi tersebut, model HWA memerlukan nilai *level*, *trend* dan *seasonal* pada waktu terakhir data yaitu $t = 132$. Berikut adalah nilai L_t , b_t dan S_t menggunakan persamaan (3)-(6) untuk $t = 120, 121, \dots, 132$.

Tabel 10. *Level*, *trend* dan *seasonal* data uji dengan HWA

Bulan	t	L_t	b_t	S_t
Desember 2022	120	22478.006	-441.002	1361.457
Januari 2023	121	22044.768	-439.449	275.501
Februari 2023	122	21337.479	-493.017	-2.899
Maret 2023	123	22604.053	-141.099	712.092
April 2023	124	20097.271	-614.235	-685.444
Mei 2023	125	21472.770	-216.288	123.189
Juni 2023	126	20607.524	-346.080	27.529
Juli 2023	127	20775.423	-243.284	57.323
Agustus 2023	128	22822.909	214.870	-953.874
September 2023	129	22094.025	26.119	-1296.694
Oktober 2023	130	22122.668	26.624	21.692
November 2023	131	21669.058	-69.423	353.522
Desember 2023	132	21086.732	-172.003	1332.962

Setelah ditentukan *level*, *trend* dan *seasonal* maka model yang digunakan untuk memprediksi nilai ekspor Indonesia dari Januari 2024 hingga Desember 2024 adalah

$$\text{HWA: } F_{132+m} = 21086.732 - 172.003m + S_{132-12+m} \quad (19)$$

dengan langkah prediksi $m = 1, 2, \dots, 12$ untuk prediksi 12 bulan selanjutnya. Hasil dari prediksi untuk tahun 2024 disajikan dalam tabel berikut.

Tabel 11. Prediksi tahun 2024 dengan HWA

Month	Nilai Ekspor (juta US\$)
Januari 2024	21190.23
Februari 2024	20739.83
Maret 2024	21282.81
April 2024	19713.28
Mei 2024	20349.90
Juni 2024	20082.24
Juli 2024	19940.03
Agustus 2024	18756.83
September 2024	18242.01
Oktober 2024	19388.39
November 2024	19548.22
Desember 2024	20355.65

Hasil prediksi menggunakan model HWA menunjukkan bahwa nilai ekspor pada tahun 2024 cenderung mengalami fluktuasi dengan tren yang melandai pada kuartal ketiga, khususnya pada bulan Agustus (18756.83 juta US\$) dan September (18242.01 juta US\$). Secara fundamental, penurunan ini tidak hanya merupakan pola teknis musiman, tetapi juga merefleksikan normalisasi harga komoditas global pasca-lonjakan pandemi serta melambatnya aktivitas manufaktur di negara-negara mitra dagang utama. Penurunan pada periode tersebut sejalan dengan koreksi harga komoditas unggulan seperti batubara dan minyak sawit mentah (CPO) di pasar internasional yang mulai mengalami titik jenuh. Namun, model berhasil menangkap sinyal pemulihan pada akhir tahun, dengan nilai prediksi Desember yang kembali meningkat ke angka 20.355,65 juta US\$. Kenaikan ini secara praktis berkorelasi dengan fenomena *year-end surge*, di mana terdapat peningkatan permintaan global untuk memenuhi kebutuhan stok akhir tahun serta penyelesaian kontrak ekspor tahunan. Dengan mengaitkan angka statistik ini pada kondisi makroekonomi, terlihat bahwa model HWA sangat efektif untuk prediksi jangka pendek karena mampu menyelaraskan pola historis dengan dinamika kebijakan perdagangan dan siklus ekonomi riil secara akurat.

4 Simpulan dan Saran

Nilai ekspor Indonesia telah dimodelkan menggunakan dua metode, yaitu model ARIMA dan metode *Holt-Winters*, dengan hasil yang baik. Dalam melakukan pemodelan ARIMA, data deret waktu perlu dilakukan *differencing* agar memenuhi sifat stasioneritas. Model ARIMA yang berhasil dibangun adalah ARIMA(3,1,2). Berdasarkan tingkat akurasi MAPE, metode Holt-Winters memberikan hasil yang lebih baik dalam memprediksi nilai ekspor Indonesia dibandingkan dengan metode ARIMA.

Penelitian ini menghasilkan model terbaik untuk memprediksi nilai ekspor Indonesia, yaitu model *Holt-Winters Additive*. Disarankan bahwa prediksi nilai ekspor Indonesia dipengaruhi oleh berbagai faktor eksternal, seperti kebijakan pemerintah pada saat itu, kondisi hubungan luar negeri, dan faktor lainnya, agar model ini dapat memberikan hasil yang lebih baik. Untuk penelitian selanjutnya, disarankan agar menambahkan variabel eksogen, seperti variabel *dummy* yang dapat menggambarkan situasi kebijakan perdagangan internasional atau krisis ekonomi, guna meningkatkan kemampuan model dalam memprediksi nilai ekspor Indonesia. Selain itu, penerapan algoritma Machine Learning atau Deep Learning, seperti Long Short-Term Memory (LSTM), guna menangani pola non-linear dan volatilitas ekstrem pascapandemi yang lebih kompleks. Selain itu, perlu dilakukan analisis komparatif pada sektor spesifik (seperti migas dan non-migas) untuk menghasilkan proyeksi yang lebih mendalam dan aplikatif bagi kebijakan ekonomi nasional dalam menghadapi ketidakpastian pasar global di masa depan.

5 Penutup

Peneliti mengucapkan terima kasih kepada tim editor dan *reviewer* untuk arahnya selama penelitian ini yang dapat meningkatkan kualitas dari *paper* ini sehingga dapat berguna untuk berbagai kebutuhan akademik.

Daftar Pustaka

- [1] Ahmar AS, Singh PK, Ruliana R, Pandey AK, Gupta S. 2023. Comparison of ARIMA, SutteARIMA, and Holt-Winters, and NNAR Models to Predict Food Grain in India. *Forecasting*. 5(1):138–152. doi:10.3390/forecast5010006.
- [2] [BPS] Badan Pusat Statistik. 2022. Statistik Perdagangan Luar Negeri Indonesia Ekspor 2021, Jilid II. [diakses 2025 Nov 6]. <https://www.bps.go.id/id/publication/2022/07/06/501562aa8f0f3df35e84671a/indonesia-foreign-trade-statistics-exports-2021--volume-ii.html>.
- [3] [BPS] Badan Pusat Statistik. 2024. Nilai Ekspor Indonesia. [diakses 2024 Sep 6]. <https://www.bps.go.id/id/>.
- [4] Bahmani-Oskooee M, Aftab M. 2017. On the asymmetric effects of exchange rate volatility on trade flows: New evidence from US-Malaysia trade at the industry level. *Econ Model*. 63:86–103. doi:10.1016/j.econmod.2017.02.004.
- [5] Cryer JD., Chan K-Sik. 2010. *Time Series Analysis : With Applications in R*. Springer.
- [6] Erlina RR, Azhar R. 2020. Forecasting model of agriculture commodity of value export of coffee: application ARIMA model. *Jurnal Teknik Pertanian Lampung*. 9(3):257–263. doi:10.23960/jtep-l.v9.i3.257-263.
- [7] Helleiner E. 2014. *The status quo crisis : global financial governance after the 2008 financial meltdown*. Oxford University Press.
- [8] Hyndman RJ, Athanasopoulos G. 2018. *Forecasting: Principles and Practice*. [diakses 2025 Sep 14]. <https://otexts.org/fpp2/>.
- [9] Juliansyah H, Ganesha Y, Nailufar F, Terfiadi SY. 2022. Effect of import and export and investment on economic growth in Indonesia (VECM analysis method). *Journal of Malikussaleh Public Economics*. 05:2614–4573.
- [10] Kang JW, Dagli S. 2018. International trade and exchange rates. *J Appl Econ*. 21(1):84–105. doi:10.1080/15140326.2018.1526878.
- [11] Krugman PR. 2003. *International economics : theory and policy*. Addison Wesley.
- [12] Munch J, Schaur G. 2018. The effect of export promotion on firm- level performance. *Am Econ J Econ Policy*. 10(1):357–387. doi:10.1257/pol.20150410.

- [13] Pires C, Martins M V. 2024. Enhancing water management: a comparative analysis of time series prediction models for distributed water flow in supply networks. *Water (Basel)*. 16(13):1827. doi:10.3390/w16131827.
- [14] Pratama AA, Agushinta R. D, Mukhyi MA. 2022. Penerapan metode Moving Average dan Exponential Smoothing untuk prediksi nilai ekspor dan impor Indonesia. *Jurnal Ilmiah FIFO*. 14(1):58. doi:10.22441/fifo.2022.v14i1.006.
- [15] Ruzekova V, Kittova Z, Steinhäuser D. 2020. Export performance as a measurement of competitiveness. *Journal of Competitiveness*. 12(1):145–160. doi:10.7441/joc.2020.01.09.
- [16] Sathyamoorthy V, Tang TC. 2018. Institutional quality and export-led growth: an empirical study. *Journal of Economic Studies*. 45(1):193–208. doi:10.1108/JES-07-2016-0139.
- [17] Sedyaningrum M, Nila S, Nuzula F. 2016. Pengaruh jumlah nilai ekspor, impor dan pertumbuhan ekonomi terhadap nilai tukar dan daya beli masyarakat di Indonesia. *Jurnal Administrasi Bisnis (JAB)*. 34(1).
- [18] Senadza B, Diaba DD. 2018. Effect of exchange rate volatility on trade in Sub-Saharan Africa☆. *Journal of African Trade*. 4(1–2):20. doi:10.1016/j.joat.2017.12.002.
- [19] Sibuea N, Ramadhan AR, Tri Aulia R, Khairunnisa S, Yendra R, Adnan A. 2022. Comparison of Linear Regression method and Holt-Winters method in oil and gas export volume forecasting in Indonesia. *International Journal of Mathematics Trends and Technology*. 68(12):7–12. doi:10.14445/22315373/ijmtt-v68i12p502.
- [20] Syukri AU. 2020. Causality between Gross Domestic Product, exports, imports, foreign exchange reserves, and foreign debt in Indonesia. *Journal of Developing Economies*. 5(2):107. doi:10.20473/jde.v5i2.18275.
- [21] Trabelsi J, Jelassi MM, Lo G Del. 2017. A volatility analysis of agricultural commodity and crude oil global markets. *Applied Economics and Finance*. 4(2):129. doi:10.11114/aef.v4i2.2086.
- [22] Zhou H, Fan J. 2023. Export structure, import demand elasticity and export stability. *World Economy*. 46(3):758–790. doi:10.1111/twec.13305.