

ANALISIS PERBANDINGAN METODE ARIMA DAN *DOUBLE EXPONENTIAL SMOOTHING* DARI *BROWN* PADA PERAMALAN INFLASI DI INDONESIA

Shella Melati Saragih^{1*}, Pasukat Sembiring²

^{1,2}Program Studi Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sumatera Utara
Email : ¹shellasrgh13@gmail.com, ²pasukat@usu.ac.id

Abstract. *This study aims to obtain the best forecasting method in predicting inflation in Indonesia by comparing the ARIMA method and Brown's Double Exponential Smoothing. The data used is inflation data in Indonesia for 8 years, starting from January 2014 to December 2021. The data to be processed is data from January 2014 to September 2021, while other data will be used to see deviations in the forecast. The analysis is carried out on inflation data patterns, forecasting time horizons, accuracy levels, and the use of each method. Based on this research, it is known that the inflation data used contains a downward trend pattern. In addition, the predictive period of both methods is most effective in the short term (less than 3 months). The results of inflation prediction using the ARIMA method obtained a MAPE of 15.163%. Meanwhile, the results of inflation prediction using Brown's Double Exponential Smoothing method obtained a MAPE of 5.068132%. The conclusion obtained is that Brown's Double Exponential Smoothing method is better for short-term inflation in Indonesia than the ARIMA method because it produces a smaller Mean Absolute Percentage Error (MAPE) value and has a faster computation time than ARIMA.*

Keywords: *ARIMA, Brown's Double Exponential Smoothing, Inflation, MAPE*

Abstrak. Penelitian ini bertujuan untuk mendapatkan metode peramalan terbaik dalam memprediksi inflasi di Indonesia dengan membandingkan metode ARIMA dan *Double Exponential Smoothing* dari *Brown*. Data yang digunakan adalah data inflasi di Indonesia selama 8 tahun, mulai dari Januari 2014 sampai Desember 2021. Data yang akan diolah adalah data pada periode Januari 2014 sampai September 2021, sedangkan data lainnya akan digunakan untuk melihat deviasi pada peramalan. Analisis dilakukan terhadap pola data inflasi, horizon waktu peramalan, tingkat akurasi, serta penggunaan dari masing-masing metode. Berdasarkan penelitian ini, diketahui bahwa data inflasi yang digunakan mengandung pola *trend* menurun. Selain itu, periode hasil prediksi dari kedua metode tersebut paling efektif dalam melakukan peramalan jangka pendek (kurang dari 3 bulan). Hasil prediksi inflasi menggunakan metode ARIMA memperoleh MAPE sebesar 15,163%. Sedangkan hasil prediksi inflasi menggunakan metode *Double Exponential Smoothing* dari *Brown* memperoleh MAPE sebesar 5,068132%. Kesimpulan yang diperoleh yaitu metode *Double Exponential Smoothing* dari *Brown* lebih baik digunakan untuk peramalan jangka pendek inflasi di Indonesia dibandingkan dengan metode ARIMA karena menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) yang lebih kecil serta memiliki waktu komputasi yang lebih cepat dibandingkan ARIMA.

Kata Kunci: *ARIMA, Double Exponential Smoothing* dari *Brown*, Inflasi, MAPE

I. PENDAHULUAN

Peramalan digunakan sebagai upaya ketika ingin memprediksi peristiwa di waktu mendatang. Berdasarkan sifat prediksi yang disusun, peramalan terbagi menjadi peramalan kualitatif dan kuantitatif. *Time series* tergolong dalam peramalan kuantitatif dan dapat diartikan sebagai upaya memprediksi peristiwa di waktu mendatang yang berlandaskan pada nilai variabel masa lampau maupun kesalahan masa lampau [1]. Pemeriksaan terhadap jenis pola data dalam *time series* diperlukan ketika ingin menyeleksi suatu metode yang tepat. Adapun jenis pola datanya, terdiri dari data horizontal atau stasioner, musiman, siklis, dan *trend* [1].

Metode ARIMA dan *Double Exponential Smoothing* dari *Brown* merupakan metode peramalan dengan model deret waktu (*time series*) [2]. Metode ARIMA memiliki kelebihan yaitu dapat diterapkan pada semua jenis pola data termasuk data *trend* meskipun pada prosesnya, data tersebut harus distasionerkan terlebih dahulu [3]. Metode ARIMA ini dikembangkan karena metode peramalan yang telah ada sebelumnya selalu dibatasi hanya untuk macam-macam pola tertentu dari data [4]. Salah satu metode yang dibatasi hanya untuk pola tertentu dari data adalah metode *Double Exponential Smoothing* dari *Brown*, dimana metode ini menggunakan asumsi adanya suatu pola *trend* dari data yang ada dan pada prosesnya data tersebut tidak perlu distasionerkan. Oleh karena itu, alasan peneliti memilih kedua metode tersebut karena baik metode ARIMA maupun *Double Exponential Smoothing* dari *Brown*, keduanya dapat digunakan untuk memprediksi data yang berpola *trend* meskipun harus melalui proses yang berbeda. Selain itu, kedua metode ini juga lebih akurat jika digunakan untuk peramalan jangka pendek karena untuk peramalan jangka panjang, metode ini akan cenderung flat [5].

Inflasi merupakan suatu masalah yang dapat diprediksi dengan menggunakan *time series* [6]. Kecenderungan umum dan berkelanjutan dari kenaikan harga-harga barang dan jasa disebut inflasi. Sebelum pandemi COVID-19 melanda Indonesia, inflasi di Indonesia telah berada pada tingkat yang cukup rendah dan mengalami *trend* menurun. Kemudian, setelah terjadinya pandemi COVID-19 mengakibatkan bertambahnya tekanan terhadap penurunan inflasi yang telah berlangsung sebelumnya karena menurunnya permintaan agregat dan memberikan tekanan penurunan tingkat harga secara umum [7].

Penelitian terkait penerapan metode ARIMA pernah dilakukan oleh Hartati [6] yang menyimpulkan bahwa metode ARIMA ini memiliki kemampuan untuk menanggulangi ketidakstabilan inflasi karena menghasilkan prediksi yang mengikuti pergerakan data asli inflasi serta mampu untuk memprediksi dengan cepat, sederhana, dan akurat terhadap data variabel yang akan diprediksi. Selanjutnya, Syahdan dan Aisyah melakukan penelitian terkait penerapan metode *Double Exponential Smoothing* dari *Brown* dalam memprediksi IHK kota Tarakan [8]. Dalam penelitian ini, dinyatakan bahwa IHK kota Tarakan menunjukkan pola data *trend*. Adanya pola *trend* pada data mengakibatkan metode *Double Exponential Smoothing* dari *Brown* digunakan dalam peramalan ini guna mengantisipasi perbedaan antara data asli dengan data hasil prediksi. Selain itu, Izza dan Riza membandingkan metode ARIMA dengan *Double Exponential Smoothing* dari *Brown* pada peramalan jumlah pengunjung Perpustakaan daerah Provinsi Jawa Tengah [9]. Pola data dalam penelitian ini menunjukkan *trend* naik dan hasil prediksi menunjukkan metode ARIMA lebih akurat

dibandingkan *Double Exponential Smoothing* dari *Brown* pada studi kasus peramalan jumlah pengunjung perpustakaan daerah Provinsi Jawa Tengah.

Uraian di atas membuat peneliti tertarik pada penelitian dan penerapan metode ARIMA dan *Double Exponential Smoothing* dari *Brown* untuk membandingkan keakuratan serta penggunaan dari kedua metode tersebut dalam memprediksi inflasi di Indonesia.

I.1 Peramalan

Peramalan dapat diartikan sebagai upaya dalam memprediksi peristiwa di waktu mendatang. Berdasarkan horizon waktu atau periode hasil prediksi, peramalan terbagi ke dalam peramalan jangka pendek, jangka menengah, dan jangka panjang [4]. Apabila periode hasil prediksi hanya pada beberapa periode tertentu di waktu mendatang (pada umumnya kurang dari tiga bulan), maka disebut peramalan jangka pendek. Apabila mencakup satu sampai dua tahun ke depan, maka disebut peramalan jangka menengah. Sedangkan, apabila melewati itu selama bertahun-tahun, maka disebut peramalan jangka panjang.

Dalam memilih teknik dan metode peramalan yang tepat untuk suatu masalah atau keadaan tertentu yang sedang dihadapi, diperlukan pedoman berupa karakteristik dari berbagai teknik dan metode peramalan yang harus diperhatikan bagi pengambil keputusan maupun analis. Beberapa diantaranya yaitu pola data, horizon waktu atau periode hasil prediksi, tingkat akurasi, dan mudah tidaknya penggunaan atau aplikasinya [4].

I.2 Analisis Deret Berkala (*Time Series*)

Pendugaan masa depan yang dilakukan berdasarkan informasi masa lampau dari suatu variabel dan/atau kesalahan masa lampau disebut deret berkala atau *time series* [1]. Jenis pola data dalam *time series* dibagi menjadi pola data horizontal atau stasioner yang terjadi ketika nilai data berfluktuasi di sekitar *mean*, pola data musiman yang terjadi ketika faktor musiman memengaruhi data sehingga data tersebut bergerak naik dan turun dalam pola yang berulang dari satu waktu ke waktu berikutnya, pola data siklis yang terjadi ketika fluktuasi ekonomi jangka panjang memengaruhi data sehingga fluktuasi data berbentuk gelombang selama periode yang tak pasti, dan pola data *trend* yang terjadi ketika selama kurun waktu tertentu, data mengalami kenaikan ataupun penurunan [1].

I.3 Kestasioneran Data

Suatu data dikatakan stasioner terhadap *variance* apabila data berfluktuasi secara konsisten atau dapat juga dilihat dari nilai parameter transformasi (λ) menggunakan diagram Box-Cox. Data dikatakan stasioner terhadap *variance* ketika nilai $\lambda = 1$. Apabila data belum stasioner terhadap *variance*, modifikasi dapat dilakukan melalui proses transformasi yaitu Transformasi Box-Cox. Persamaan untuk transformasi ini yaitu [10]:

$$T(X_t) = \begin{cases} \frac{X_t^\lambda - 1}{\lambda} & \text{untuk } \lambda \neq 0 \\ \ln X_t & \text{untuk } \lambda = 0 \end{cases} \quad (1)$$

dimana λ merupakan parameter transformasi dan X_t merupakan nilai data pada periode t .

Suatu data dikatakan stasioner terhadap *mean* jika untuk semua *lag*, koefisien autokorelasinya tidak berbeda dari nol atau dapat juga berbeda dari nol tetapi hanya untuk $lag < 3$ [11]. Apabila data belum stasioner terhadap *mean*, modifikasi dapat dilakukan melalui proses *differencing* yaitu nilai data suatu periode dikurangi nilai data periode sebelumnya. Secara umum persamaan untuk *differencing* orde ke-*d* yaitu [12]:

$$X_t^d = (1 - B)^d X_t \quad (2)$$

dimana X_t^d adalah *differencing* orde ke-*d*, X_t adalah nilai data pada periode *t*, *B* adalah operator *backshift*, dimana $X_t B = X_{t-1}$.

I.4 Fungsi Autokorelasi (ACF) dan Fungsi Autokorelasi Parsial (PACF)

Suatu fungsi yang memperlihatkan seberapa besar hubungan ataupun korelasi pada data yang sama namun terpisah oleh waktu *lag* *k* disebut fungsi autokorelasi (ACF). Rumus untuk menentukan nilai koefisien ACF sampel *lag* ke-*k* yaitu [13]:

$$r_k = \frac{\gamma_k}{\gamma_0} = \frac{\sum_{t=k+1}^n (X_t - \bar{X})(X_{t-k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (3)$$

dimana X_t adalah nilai data pada periode *t*, \bar{X} adalah nilai *mean* pada data, *k* adalah waktu *lag*, dan *n* adalah jumlah data observasi.

Suatu fungsi yang memperlihatkan tingkat keeratan X_t dengan X_{t-k} ketika pengaruh dari waktu *lag* 1,2,3, ..., *k* - 1 dianggap terpisah disebut fungsi autokorelasi parsial (PACF). Rumus untuk menentukan nilai koefisien PACF sampel *lag* ke-*k* yaitu [13]:

$$\phi_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \phi_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} r_j} \quad (4)$$

dimana $\phi_{k,j} = \phi_{k-1,j} - \phi_{kk} \phi_{k-1,k-j}$ untuk $j = 1, 2, \dots, k - 1$

I.5 Autoregressive Integrated Moving Average (ARIMA)

Metode ARIMA hanya berlaku pada data yang stasioner ataupun yang menjadi stasioner dengan proses *differencing*. Kelompok model *time series* linear yang terdapat dalam metode ini adalah model *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA), dan *Autoregressive Integrated Moving Average* (ARIMA) [14]. Dengan menggunakan operator *backshift*, model ARIMA (*p,d,q*) ini dinyatakan sebagai [10]:

$$\phi(B)(1 - B)^d X_t = \theta(B)e_t \quad (5)$$

dimana $\phi(B) = 1 - \phi_1(B) - \phi_2(B)^2 \dots - \phi_p(B)^p$ merupakan operator *backshift* AR (*p*), $\theta(B) = 1 - \theta_1(B) - \theta_2(B)^2 - \dots - \theta_q(B)^q$ merupakan operator *backshift* MA (*q*), $(1 - B)^d$ merupakan operator *differencing* orde *d*, dan e_t merupakan galat model.

I.6 Estimasi dan Uji Signifikansi Parameter

Proses estimasi parameter dimulai dengan menetapkan nilai parameter awal kemudian dilanjutkan dengan proses iterasi hingga mendapatkan nilai *sum squared error* terkecil [11]. Hipotesis dalam uji signifikansi parameter adalah sebagai berikut [5]:

$H_0 : \phi_i = 0$ atau $\phi_j = 0$ (parameter tidak signifikan)

$H_1 : \phi_i \neq 0$ atau $\phi_j \neq 0$ (parameter signifikan)

dengan $i = 1, 2, \dots, p$ dan $j = 1, 2, \dots, q$

Statistik Uji:

$$t = \frac{\hat{\phi}}{SE(\hat{\phi})} \text{ atau } t = \frac{\hat{\theta}}{SE(\hat{\theta})} \quad (6)$$

dimana:

$$SE(\hat{\phi}) \text{ atau } SE(\hat{\theta}) = \frac{1}{\sqrt{n}}$$

$\hat{\phi}$ atau $\hat{\theta}$ = estimasi parameter model

n = banyaknya data

Kriteria Uji:

Tolak H_0 apabila $|t| > t_{\frac{\alpha}{2}, df}$ atau $p_{value} < \alpha$ dimana df atau derajat kebebasan merupakan banyaknya pengamatan dikurang banyaknya parameter ($df = n - p$) [5].

I.7 Uji Kesesuaian Model

Dalam model ARIMA (p, d, q), untuk memeriksa apakah model tersebut cocok digunakan dalam peramalan, maka dilakukan pemeriksaan melalui uji asumsi *white noise*. Uji ini dilakukan untuk memeriksa apakah terdapat korelasi antar *lag* dimana model dianggap cocok untuk peramalan ketika tidak terdapatnya autokorelasi residual (asumsi *white noise* terpenuhi). Hal ini dapat dilihat dari *Ljung-Box* nya [9].

Hipotesis dalam uji *white noise*:

$H_0 : r = 0$ (asumsi *white noise* terpenuhi)

$H_1 : r \neq 0$ (asumsi *white noise* tidak terpenuhi)

Statistik Uji *Ljung-Box* dengan rumus [11]:

$$Q = n(n+2) \sum_{k=1}^K \frac{r_k^2}{n-k} \quad (7)$$

dimana:

n = jumlah data observasi

r_k = nilai ACF residual *lag* ke- k

k = nilai *lag*

K = maksimum *lag*.

Kriteria Uji [5]:

Tolak H_0 apabila $Q > \chi_{\alpha, df}^2$ atau $p_{value} < \alpha$ dimana $df = K - p - q$.

I.8 Double Exponential Smoothing dari Brown

Metode ini melakukan proses pemulusan sebanyak dua kali untuk menyesuaikan atau mengantisipasi perbedaan antara data asli dengan hasil prediksi jika terdapatnya *trend* pada data dengan cara menambahkan nilai *smoothing* kedua ke nilai-nilai *smoothing* pertama [8].

Tahapan dalam penggunaan metode *Double Exponential Smoothing* dari *Brown* yaitu:

- a. Mencari nilai *smoothing* pertama dengan rumus [8]:

$$S'_t = (\alpha X_t) + (1 - \alpha)S'_{t-1} \quad (8)$$

- b. Mencari nilai *smoothing* kedua dengan rumus [8]:

$$S''_t = (\alpha S'_t) + (1 - \alpha)S''_{t-1} \quad (9)$$

- c. Mencari nilai konstanta *smoothing* dengan rumus [8]:

$$a_t = S'_t + (S'_t - S''_t) = 2S'_t - S''_t \quad (10)$$

- d. Mencari nilai koefisien *trend* dengan rumus [8]:

$$b_t = \frac{\alpha}{(1 - \alpha)} (S'_t - S''_t) \quad (11)$$

- e. Melakukan peramalan dengan rumus [8]:

$$F_{t+m} = a_t + b_t m \quad (12)$$

dimana :

S'_t	= nilai <i>smoothing</i> pertama pada periode t
S''_t	= nilai <i>smoothing</i> kedua pada periode t
a_t	= nilai konstanta <i>smoothing</i> pada periode t
b_t	= nilai koefisien <i>trend</i> pada periode t
α	= parameter <i>smoothing</i> dengan nilai antara 0 sampai 1
m	= jumlah periode waktu di masa mendatang yang diprediksi
X_t	= nilai data pada periode t
F_{t+m}	= nilai prediksi untuk m periode berikutnya.

I.10 Mean Absolute Percentage Error (MAPE)

Salah satu indikator untuk menghitung nilai kesalahan prediksi adalah MAPE [2]. Indikator ini mengukur keakuratan peramalan dengan cara persentase kesalahan absolute atau rata-rata dari total persentase kesalahan. Rumus untuk menghitung MAPE adalah [15]:

$$MAPE = \sum_{t=1}^n \frac{(|PE_t|)}{n} \quad (13)$$

Adapun rumus untuk menghitung *Percentage Error* (PE) pada periode t adalah:

$$PE_t = \left(\frac{X_t - F_t}{X_t} \right) \times 100\% \quad (14)$$

dimana :

X_t	= nilai data pada periode t
F_t	= prediksi pada waktu ke- t
n	= banyaknya periode waktu.

II. METODOLOGI PENELITIAN

II.1 Pengumpulan Data

Jenis data yang digunakan dalam penelitian ini adalah data sekunder dari BPS Sumatera Utara yang berbentuk *time series* yaitu data inflasi di Indonesia mulai dari Januari 2014 sampai Desember 2021 (96 bulan). Sebanyak 93 data akan diolah (Januari 2014 sampai September 2021) untuk mendapatkan model dan 3 data lainnya (Oktober 2021 sampai Desember 2021) akan digunakan untuk mencari nilai MAPE terkecil diantara kedua metode.

II.2 Analisis Pola Data Asli Inflasi

Menganalisis pola yang terjadi pada masa lampau dengan melakukan plot data asli inflasi periode Januari 2014 sampai September 2021 dan mengidentifikasi pola dari data tersebut.

II.3 Pengolahan Data Menggunakan Metode ARIMA

Berikut merupakan tahapan-tahapan pengolahan data menggunakan metode ARIMA:

- Menguji kestasioneran data terhadap *variance* menggunakan diagram Box-Cox.
- Menguji kestasioneran data terhadap *mean* menggunakan plot ACF.
- Identifikasi model sementara menggunakan plot ACF dan PACF.
- Pemilihan model ARIMA terbaik dengan estimasi parameter model dugaan dan menguji signifikansi parameter tersebut.
- Melakukan uji kesesuaian model.
- Melakukan peramalan data inflasi.

II.4 Pengolahan Data Menggunakan Metode *Double Exponential Smoothing* dari *Brown*

Berikut merupakan tahapan-tahapan pengolahan data menggunakan metode *Double Exponential Smoothing* dari *Brown*:

- Pemilihan nilai parameter (α) terbaik secara *trial and error* dengan indikator MAPE terkecil.
- Menentukan nilai *smoothing* pertama.
- Menentukan nilai *smoothing* kedua.
- Menentukan nilai konstanta *smoothing*.
- Menentukan nilai koefisien *trend*.
- Melakukan peramalan data inflasi.

II.5 Analisis Perbandingan Hasil Prediksi


Analisis perbandingan dilakukan berdasarkan:

- Horizon waktu
Hasil prediksi dianalisis untuk melihat cakupan periode hasil prediksi dari masing-masing metode atau metode manakah yang paling efektif untuk melakukan peramalan jangka pendek.

- b. Tingkat akurasi peramalan
Akurasi peramalan dievaluasi dengan menggunakan nilai MAPE dari hasil prediksi kedua metode tersebut dimana peramalan dikatakan semakin akurat ketika nilai MAPE semakin rendah.
- c. Penggunaan metode
Mudah tidaknya penggunaan atau aplikasi dari masing-masing metode.

III. HASIL DAN PEMBAHASAN

Berikut merupakan plot data asli inflasi di Indonesia dari Januari 2014 sampai September 2021 yang diperoleh dari BPS Sumatera Utara:




Gambar 1. Plot Data Asli Inflasi dari Januari 2014 - September 2021

Grafik di atas menunjukkan kecenderungan data yang menurun seiring berjalannya waktu atau menunjukkan pola data *trend* menurun. Selain itu, *variance* pada data awal memiliki fluktuasi yang besar, namun seiring berjalannya waktu *variance* data tersebut semakin kecil. Berdasarkan Gambar 1, data asli inflasi di Indonesia dari Januari 2014 sampai September 2021 tidak stasioner karena *mean* dan *variance* tidak konstan dari waktu ke waktu. Dengan adanya pola *trend* pada grafik ini jelas menunjukkan bahwa data tersebut dapat diolah dengan menggunakan metode ARIMA maupun *Double Exponential Smoothing* dari *Brown*.

III.1 Pengolahan Data dengan Metode ARIMA


Berikut merupakan diagram Box-Cox data asli inflasi di Indonesia:



Gambar 2. Plot Box-Cox Data Asli Inflasi

Nilai $\lambda = 0$ atau $\lambda \neq 1$ yang diperoleh berdasarkan Gambar 2, mengindikasikan ketidakstasioneran data terhadap *variance* sehingga data membutuhkan proses transformasi. Berdasarkan persamaan (1), ketika nilai $\lambda = 0$, maka data ditransformasi menjadi $\ln X_t$.

Berikut merupakan diagram Box-Cox hasil transformasi data inflasi yang disajikan pada Gambar 3.



Gambar 3. Plot Box-Cox Data Inflasi setelah Proses Transformasi

Nilai $\lambda = 1$ yang diperoleh berdasarkan Gambar 3, mengindikasikan bahwa telah tercapainya kestasioneran data terhadap *variance* setelah proses transformasi pada data inflasi.

Kestasioneran data terhadap *mean* dapat diketahui berdasarkan plot koefisien autokorelasi (ACF) dari data yang telah ditransformasi. Perhitungan nilai koefisien autokorelasi dari data yang telah ditransformasi dilakukan dengan menggunakan persamaan (3).


Untuk $k = 1$ dan $\bar{X} = 1,22292$, diperoleh:

$$r_1 = \frac{(X_2 - \bar{X})(X_1 - \bar{X}) + (X_3 - \bar{X})(X_2 - \bar{X}) + \dots + (X_{93} - \bar{X})(X_{92} - \bar{X})}{(X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 + \dots + (X_{93} - \bar{X})^2}$$

$$r_1 = \frac{20,65540817}{21,98318712} = 0,939600$$

Perhitungan yang sama dilanjutkan untuk $k = 2,3, \dots$ hingga diperoleh dan dilakukan plot

Selanjutnya dilakukan plot koefisien ACF sampel *lag* ke-1,2,3,... dari data inflasi setelah proses transformasi sebagai mana ditampilkan pada Gambar 4.



Gambar 4. Plot ACF Data Inflasi setelah Proses Transformasi

Karena didapati lebih dari dua *lag* koefisien autokorelasi suatu data berbeda dari nol dan perlahan mengecil membentuk garis lurus, maka data inflasi setelah ditransformasi dikatakan belum stasioner terhadap *mean* dan membutuhkan proses *differencing*.

Differencing pertama dari data yang telah ditransformasi dilakukan dengan menggunakan persamaan (2).


Untuk $t = 2$ dan orde pertama ($d = 1$) diperoleh:

$$X'_2 = (1 - B)^1 X_2 = X_2 - X_2 B$$

$$X'_2 = X_2 - X_1 = 2,04769 - 2,10657 = -0,058877$$

Perhitungan yang sama dilanjutkan untuk $t = 3, 4, \dots, 93$.


Selanjutnya dilakukan plot ACF data setelah proses *differencing* pertama yaitu ditampilkan pada Gambar 5.



Gambar 5. Plot ACF Data setelah Proses *Differencing* Pertama

Setelah dilakukan *differencing* pertama, pada Gambar 5 dapat dilihat bahwa jumlah koefisien autokorelasi yang berbeda dari nol kurang dari 3 *lag* atau hanya terdapat satu koefisien autokorelasi yang keluar dari garis interval kepercayaan yaitu pada *lag* 12 sehingga mengindikasikan bahwa telah tercapainya kestasioneran data terhadap *mean*.

Ketika telah tercapai kestasioneran data terhadap *variance* dan *mean*, selanjutnya hasil plot ACF dan PACF dari data tersebut digunakan sebagai alat untuk mengidentifikasi nilai orde p dan q dalam model ARIMA (p, d, q). Adapun plot PACF data setelah proses *differencing* pertama yaitu sebagai mana ditampilkan pada Gambar 6.



Gambar 6. Plot PACF Data setelah Proses *Differencing* Pertama

Berdasarkan Gambar 6, terdapat satu nilai PACF yang keluar dari garis interval kepercayaan sehingga diduga model sementara memiliki orde AR (1) dengan model ARIMA dugaan yakni ARIMA (1,1,0). Berdasarkan Gambar 5, terdapat satu nilai ACF yang keluar dari interval kepercayaan sehingga diduga model sementara memiliki orde MA (1) dengan model ARIMA dugaan yakni ARIMA (0,1,1). Selain itu, sesuai dengan keterangan dimana nilai AR (1), *differencing* pertama ($d = 1$) dan MA (1), maka dapat diperoleh model ARIMA dugaan lain yakni ARIMA (1,1,1).

Setelah memperoleh tiga model ARIMA dugaan melalui proses identifikasi, selanjutnya dilakukan pengujian signifikansi parameter terhadap ketiga model dugaan tersebut untuk mendapatkan model ARIMA terbaik.

Tabel 1. Pengujian Signifikansi Parameter Model ARIMA (1,1,0), ARIMA (0,1,1), dan ARIMA (1,1,1)

Model	Hasil Pengujian					Signifikansi
	AR/MA	Koefisien	SE Koefisien	T-Value	P-Value	T-Value
ARIMA (1,1,0)	AR 1	0,245	0,102	2,40	0,019	Signifikan
ARIMA (0,1,1)	MA 1	-0,3727	0,0979	-3,81	0,000	Signifikan
ARIMA (1,1,1)	AR 1	-0,188	0,282	-0,67	0,506	Tidak Signifikan
	MA 1	-0,522	0,245	-2,13	0,036	Signifikan

Model ARIMA (1,1,0) dan ARIMA (0,1,1) merupakan model yang masing-masing $|t| > t_{\frac{\alpha}{2},df} = 1,98667$ sehingga keputusan untuk kedua model tersebut adalah tolak H_0 yaitu nilai parameter signifikan dengan nilai parameter yang diperoleh masing-masing adalah $\theta_1 = 0,245$ dan $\theta_1 = -0,3727$. Sedangkan pada model ARIMA (1,1,1), nilai parameter tidak signifikan karena pada AR 1, $|t| < t_{\frac{\alpha}{2},df}$ yaitu $0,67 < 1,98667$.

Kemudian dilakukan pengujian nilai *Mean Squared Error* (MSE) terhadap model ARIMA (1,1,0) dan ARIMA (0,1,1) dimana nilai MSE dari model yang terpilih harus minimum.

Tabel 2. Nilai MSE Model ARIMA (1,1,0), ARIMA (0,1,1)

Model	Nilai MSE
ARIMA (1,1,0)	0,263489
ARIMA (0,1,1)	0,253289

Model ARIMA (0,1,1) terpilih sebagai model terbaik karena nilai MSE dari model tersebut lebih kecil dibandingkan model berdasarkan hasil pengujian nilai MSE, serta mempunyai nilai parameter yang signifikan berdasarkan pengujian signifikansi parameter.

Selanjutnya dilakukan uji asumsi *white noise* untuk memeriksa apakah terdapat korelasi antar *lag* menggunakan Ljung-Box. Model dianggap layak untuk peramalan ketika tidak terdapatnya autokorelasi residual. Dengan menggunakan bantuan *software* minitab, berikut merupakan hasil uji Ljung-Box model ARIMA (0,1,1):

Tabel 3. Ljung-Box Model ARIMA (0,1,1)

Model ARIMA	Lag	df	Q	$\chi^2_{\alpha,df}$	pvalue
	24	22	26,88	33,9244	0,216
ARIMA (0,1,1)	36	34	34,63	48,6023	0,437
	48	46	38,52	62,8296	0,775

Berdasarkan hasil uji Ljung-Box pada model ARIMA (0,1,1), diperoleh bahwa nilai $Q < \chi^2_{\alpha,df}$ yang mengindikasikan bahwa model ini memenuhi asumsi *white noise* dan selanjutnya dapat digunakan untuk peramalan inflasi.

Model ARIMA (0,1,1) dapat dinyatakan dengan persamaan:

$$X_t = X_{t-1} + e_t + 0,3727e_{t-1}$$

Berikut merupakan hasil prediksi inflasi periode Oktober 2021 sampai Desember 2021 menggunakan ARIMA:

Tabel 4. Hasil Prediksi ARIMA

Periode	Bulan	Hasil Prediksi
94	Oktober	1,55941
95	November	1,48671
96	Desember	1,41402

III.2 Pengolahan Data dengan Metode *Double Exponential Smoothing* dari *Brown*

Pada tahap ini akan digunakan indikator yaitu *Mean Absolute Percentage Error* (MAPE) terkecil ketika ingin memilih nilai terbaik untuk parameter α . Pemilihan terhadap parameter α terbaik dilakukan secara *trial and error* dengan nilai α yang ditetapkan yaitu antara 0,1 hingga 0,9.

Dengan menggunakan nilai parameter $\alpha = 0,1$ dan rumus pada persamaan (14):

F_1 belum dapat ditentukan sehingga nilai PE_1 juga tidak dapat dihitung.

$$PE_2 = \left(\frac{X_2 - F_2}{X_2} \right) \times 100 = \left(\frac{7,75 - 8,22}{7,75} \right) \times 100 = -6,0645$$

dan seterusnya hingga perhitungan $t = 93$ diperoleh PE_{93} sebagai berikut:

$$PE_{93} = \left(\frac{X_{93} - F_{93}}{X_{93}} \right) \times 100 = \left(\frac{1,6 - 1,24065}{1,6} \right) \times 100 = 22,4594$$

Dengan menggunakan persamaan (13), nilai MAPE untuk parameter $\alpha = 0,1$ dapat dihitung sebagai berikut:

$$MAPE = \frac{\sum_{t=1}^N \frac{|PE_t|}{N}}{93} = \frac{|PE_1| + |PE_2| + |PE_3| + \dots + |PE_{93}|}{93}$$

$$MAPE = \frac{0 + 6,0645 + 11,0109 + \dots + 22,4594}{93} = 16,3638$$

Perhitungan yang sama dilakukan dengan menggunakan nilai parameter $\alpha = 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; \text{ dan } 0,9$.

Tabel 5. Perhitungan MAPE dengan Nilai Parameter $\alpha = 0,1$ sampai $0,9$

Parameter (α)	MAPE (%)
0,1	16,36385
0,2	13,13218
0,3	11,68146
0,4	11,20258
0,5	10,79207
0,6	10,50159
0,7	10,45489
0,8	10,52193
0,9	10,53128

Nilai MAPE terkecil terletak pada parameter $\alpha = 0,7$ yaitu sebesar 10,45489. Maka untuk perhitungan selanjutnya akan menggunakan parameter $\alpha = 0,7$.

Perhitungan nilai *smoothing* pertama dengan parameter $\alpha = 0,7$ dapat dilakukan menggunakan persamaan (8).

Untuk $t = 1$, nilai S'_1 ditetapkan sama dengan nilai pada data aktual X_1 karena nilai S'_{1-1} tidak tersedia sehingga diperoleh $S'_1 = X_1 = 8,22$

Untuk $t = 2$, nilai $S'_2 = 0,7X_2 + 0,3S'_1 = (0,7)(7,75) + (0,3)(8,22) = 7,891$

dan seterusnya hingga perhitungan $t = 93$ diperoleh:

$$S'_{93} = 0,7X_{93} + 0,3S'_{92} = (0,7)(1,6) + (0,3)(1,5592) = 1,5877$$

Perhitungan nilai *smoothing* kedua dengan parameter $\alpha = 0,7$ dapat dilakukan menggunakan persamaan (9).

Untuk $t = 1$, nilai S''_1 ditetapkan sama dengan nilai pada data aktual X_1 karena nilai S''_{1-1} tidak tersedia sehingga diperoleh $S''_1 = X_1 = 8,22$

Untuk $t = 2$, nilai $S''_2 = 0,7S'_2 + 0,3S''_1 = (0,7)(7,891) + (0,3)(8,22) = 7,9897$

dan seterusnya hingga perhitungan $t = 93$ diperoleh:

$$S''_{93} = 0,7S'_{93} + 0,3S''_{92} = (0,7)(1,5877) + (0,3)(1,5343) = 1,5717$$

Dengan menggunakan rumus pada persamaan (10), dilakukan perhitungan konstanta pemulusan sebagai berikut:

Untuk $t = 1$, $a_1 = 2S'_1 - S''_1 = 2(8,22) - 8,22 = 8,22$

Untuk $t = 2$, $a_2 = 2S'_2 - S''_2 = 2(7,891) - 7,9897 = 7,7923$

dan seterusnya hingga perhitungan $t = 93$ diperoleh:

$$a_{93} = 2S'_{93} - S''_{93} = 2(1,5877) - 1,5717 = 1,6037$$

Dengan menggunakan persamaan (11), dilakukan perhitungan nilai koefisien *trend* dengan parameter $\alpha = 0,7$.

Untuk $t = 1$, $b_1 = \frac{0,7}{0,3}(S'_1 - S''_1) = \frac{0,7}{0,3}(8,22 - 8,22) = 0$

Untuk $t = 2$, $b_2 = \frac{0,7}{0,3}(S'_2 - S''_2) = \frac{0,7}{0,3}(7,891 - 7,9897) = -0,2303$

dan seterusnya hingga perhitungan $t = 93$ diperoleh:

$$b_{93} = \frac{0,7}{0,3}(S'_{93} - S''_{93}) = \frac{0,7}{0,3}(1,5877 - 1,5717) = 0,0374$$

Selanjutnya dilakukan prediksi inflasi untuk 3 bulan kedepan untuk periode Oktober 2021 sampai Desember 2021 menggunakan rumus pada persamaan (12) dengan nilai $t = 93$ dan nilai $m = 1,2,3$. Maka persamaan modelnya $F_{93+m} = a_{93} + b_{93}(m)$.

Tabel 6. Hasil Prediksi *Double Exponential Smoothing* dari *Brown*

Periode	Bulan	Hasil Prediksi
94	Oktober	1,6412
95	November	1,64786
96	Desember	1,7160

III.3 Analisis Perbandingan Hasil Prediksi

Dengan mengurangkan hasil prediksi tiap metode dengan data asli inflasi, adapun *error* yang dihasilkan pada setiap periode dari kedua metode yaitu :

Tabel 7. *Error* dari hasil Prediksi ARIMA dan *Double Exponential Smoothing* dari *Brown*

Periode	Bulan	<i>Error</i> dari ARIMA	<i>Error</i> dari DES <i>Brown</i>
94	Oktober	0,1059	0,0188
95	November	0,26329	0,10214
96	Desember	0,455898	0,154

Kedua metode menghasilkan peramalan jangka pendek (kurang dari 3 bulan) yang cenderung lebih akurat dibanding peramalan jangka menengah maupun jangka panjang. Hal ini disebabkan karena pada peramalan jangka pendek, faktor-faktor yang mempengaruhi inflasi relatif masih konstan sedangkan makin panjang periode prediksi, maka semakin besar pula kemungkinan terjadinya perubahan faktor-faktor yang mempengaruhi inflasi. Namun, jika dibandingkan *error* pada tiap periode yang dihasilkan oleh kedua metode, *Double Exponential Smoothing* dari *Brown* lebih efektif untuk melakukan peramalan jangka pendek.

Perhitungan akurasi metode ARIMA dilakukan dengan membandingkan data asli inflasi dengan hasil prediksi, yaitu:

Tabel 8. Perbandingan Data Asli Inflasi dengan Hasil Prediksi Metode ARIMA

Bulan	Data Asli Inflasi (X_t)	Hasil Prediksi ARIMA (F_t)	$PE_t = \left(\frac{X_t - F_t}{X_t} \right) \times 100$
Oktober 2021	1,66	1,55941	6,05964
November 2021	1,75	1,48671	15,04514
Desember 2021	1,87	1,41402	24,38396

Dengan menggunakan persamaan (13), nilai MAPE metode ARIMA yaitu:

$$MAPE = \sum_{t=1}^n \frac{(|PE_t|)}{n} = 15,163$$

Perhitungan akurasi metode *Double Exponential Smoothing* dari *Brown* dilakukan dengan membandingkan data asli inflasi dengan hasil prediksi, yaitu:

Tabel 9. Perbandingan Data Asli Inflasi dengan Hasil Prediksi Metode *Double Exponential Smoothing* dari *Brown*

Bulan	Data Aktual (X_t)	Hasil Peramalan (F_t)	$PE_t = \left(\frac{X_t - F_t}{X_t} \right) \times 100$
Oktober 2021	1,66	1,6412	1,13253
November 2021	1,75	1,64786	5,836571
Desember 2021	1,87	1,7160	8,235294

Dengan menggunakan persamaan (13), nilai MAPE metode *Double Exponential Smoothing* dari *Brown* yaitu:

$$MAPE = \sum_{t=1}^n \frac{(|PE_t|)}{n} = 5,068132$$

Berdasarkan perhitungan MAPE dari kedua metode di atas, dapat diketahui bahwa nilai MAPE dari metode *Double Exponential Smoothing* dari *Brown* yaitu 5,068132% lebih kecil dibandingkan nilai MAPE dari metode ARIMA yaitu 15,163%.

Berdasarkan pengolahan data yang telah dilakukan, metode *Double Exponential Smoothing* dari *Brown* memiliki waktu komputasi yang lebih cepat jika dibandingkan dengan metode ARIMA. Hal ini dikarenakan metode ARIMA harus melakukan proses untuk menstasionerkan data dengan pola *trend* namun metode *Double Exponential Smoothing* dari *Brown* dalam penerapannya tidak perlu melakukan proses untuk menstasionerkan data dengan pola *trend* (non-stasioner).

IV. KESIMPULAN

Data inflasi di Indonesia dari Januari 2014 sampai September 2021 mengandung pola *trend* menurun sehingga dapat diolah dengan menggunakan metode ARIMA maupun *Double Exponential Smoothing* dari *Brown*. Model ARIMA terbaik yaitu ARIMA (0,1,1) dengan persamaan modelnya $X_t = X_{t-1} + e_t + 0,3727e_{t-1}$ dan hasil prediksi inflasi yang diperoleh dari bulan Oktober 2021 sampai Desember 2021 secara berurutan adalah 1,55941; 1,48671 dan 1,41402. Adapun hasil perhitungan MAPE yang diperoleh yaitu 15,163%. Hasil prediksi inflasi menggunakan metode *Double Exponential Smoothing* dari *Brown* dari bulan Oktober 2021 sampai Desember 2021 secara berurutan adalah 1,6412; 1,64786 dan 1,7160 dengan persamaan modelnya yaitu $F_{t+m} = 1,60379 + 0,0374(m)$. Adapun hasil perhitungan MAPE yang diperoleh yaitu 5,068132%. Metode *Double Exponential Smoothing* dari *Brown* lebih baik dibandingkan metode ARIMA karena menghasilkan nilai MAPE yang lebih kecil serta memiliki waktu komputasi yang lebih cepat dibandingkan ARIMA dalam penggunaannya untuk memprediksi inflasi di Indonesia.

REFERENSI

- [1] S. Makridakis, S. Wheelwright C, and V. E. McGee, "Metode dan Aplikasi Peramalan," *Bin. Aksara*, 1999.
- [2] A. Zahrunnisa, R. D. Nafalana, I. A. Rosyada, and E. Widodo, "Perbandingan Metode Exponential Smoothing Dan Arima Pada Peramalan Garis Kemiskinan Provinsi Jawa

- Tengah,” *J. Lebesgue J. Ilm. Pendidik. Mat. Mat. dan Stat.*, vol. 2, no. 3, pp. 300–314, 2021, doi: 10.46306/lb.v2i3.91.
- [3] A. Nofiyanto, R. A. Nugroho, and D. Kartini, “Peramalan Permintaan Paving Blok Dengan Metode ARIMA,” *Proc. Konf. Nas. Sist. dan Inform.*, vol. 9, pp. 54–59, 2015.
- [4] S. Assauri, *Teknik dan Metode Peramalan: Penerapannya dalam Ekonomi dan Dunia Usaha*. Jakarta: Lembaga Penerbit Fakultas Ekonomi UI, 1984.
- [5] Y. I. AJUNU, N. ACHMAD, and M. R. F. PAYU, “PERBANDINGAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DAN METODE DOUBLE EXPONENTIAL SMOOTHING DARI HOLT DALAM MERAMALKAN NILAI IMPOR DI INDONESIA,” *Jambura J. Probab. Stat.*, vol. 1, no. 1, 2020, doi: 10.34312/jjps.v1i1.5393.
- [6] H. Hartati, “Penggunaan Metode Arima Dalam Meramal Pergerakan Inflasi,” *J. Mat. Sains dan Teknol.*, vol. 18, no. 1, pp. 1–10, 2017, doi: 10.33830/jmst.v18i1.163.2017.
- [7] D. Friawan and Y. E. Kurnia, “Pandemi Covid-19 dan Ancaman Inflasi di Indonesia?,” *CSIS Comment.*, vol. CSIS Comme, no. September, pp. 1–11, 2021.
- [8] S. Syahdan and S. Aisyah, “Peramalan Indeks Harga Konsumen (IHK) Kota Tarakan dengan Metode Double Exponential Smoothing dari Brown PERAMALAN INDEKS HARGA KONSUMEN (IHK) KOTA TARAKAN DENGAN METODE DOUBLE EXPONENTIAL SMOOTHING DARI BROWN (FORECASTING OF CONSUMER PRICE INDEX (CPI) TA,” *J. Mat. dan Pendidik. Mat.*, vol. 5, no. 1, p. 54, 2020.
- [9] P. Metode, A. Box, and J. Dengan, “Perbandingan Metode Arima Box -Jenkins Dengan Metode Double Exponential Smoothing Dari Brown Dalam Memprediksi Jumlah Pengunjung Perpustakaan Daerah Provinsi Jawa Tengah Izza Hasanul Muna , Riza Arifudin berdasarkan atas tingkah laku dari gejala yang suda,” no. November 2014, 2020.
- [10] J. H. Maindonald, “Time Series Analysis With Applications in R, Second Edition by Jonathan D. Cryer, Kung-Sik Chan,” *Int. Stat. Rev.*, vol. 77, no. 2, 2009, doi: 10.1111/j.1751-5823.2009.00085_1.x.
- [11] S. Mulyono, “Peramalan Harga Saham dan Nilai Tukar: Teknik Box-Jenkins,” *Econ. Financ. Indones.*, vol. 48, 2000.
- [12] C. Ifeanyichukwu Ugoh, N. C. Nwabueze, N. A. Simeon, E. T. Chinaza, and O. C. Ogedi, “Comparative Performance of Simple Exponential Smoothing, Brown’s Linear Trend and ARIMA Model on Forecasting Neonatal Mortality Rate in Nigeria,” *Asian J. Probab. Stat.*, vol. 16, no. 1, pp. 9–19, 2022, doi: 10.9734/ajpas/2022/v16i130391.
- [13] W. W. S. Wei, “William W.S. Wei - Time Series Analysis _ Univariate and Multivariate Methods (2nd Edition)-Addison Wesley (2005).pdf,” *New introduction to Multiple Time Series Analysis*. pp. 1–764, 2006.
- [14] R. J. Djami and Y. W. A. Nanlohy, “Peramalan Indeks Harga Konsumen di Kota Ambon Menggunakan Autoregressive Integrated Moving Average (ARIMA) dan Double Exponential Smoothing,” *Var. J. Stat. Its Appl.*, vol. 4, pp. 1–14, 2022.
- [15] M. A. Maricar, “Analisa perbandingan nilai akurasi moving average dan exponential smoothing untuk sistem peramalan pendapatan pada Perusahaan XYZ,” *J. Sist. dan Inform.*, vol. 13, no. 2, pp. 36–45, 2019.