

PERBANDINGAN METODE DALAM PREDIKSI HASIL PRODUKSI TEH DI INDONESIA

Ayi Salsa Bella¹, Adinda Ika Sukarni², Hani Khaulasari³

¹Universitas Islam Negeri Sunan Ampel Surabaya, h92219042@student.uinsby.ac.id

²Universitas Islam Negeri Sunan Ampel Surabaya, h72219042@student.uinsby.ac.id

³Universitas Islam Negeri Sunan Ampel Surabaya, hani.khaulasari@uinsby.ac.id

Abstrak: Sektor pertanian menjadi salah satu sektor yang terpenting dalam meningkatkan pembangunan ekonomi di Indonesia. Penyumbang *surplus* terbesar dalam sektor pertanian yaitu subsektor perkebunan dimana teh merupakan salah satu komoditas yang menjadi unggulan didalamnya. Sehingga untuk memenuhi suatu kebutuhan pasar dan meningkatkan perekonomian di Indonesia, diperlukan adanya rencana dalam menentukan kebutuhan produksi dengan tepat. Dari banyaknya tanaman perkebunan yang terdapat banyak manfaatnya yaitu perkebunan teh. Perkebunan teh dapat dijadikan sebagai tempat wisata. Selain itu, di setiap perkebunan teh pasti tidak luput dari adanya pabrik pembuatan teh sehingga menghasilkan produk teh yang sangat beragam macamnya. Tujuan dari penelitian ini adalah untuk merencanakan suatu kegiatan produksi dibutuhkan yang namanya prediksi atau peramalan yang merupakan suatu tahap awal sebagai dasar dalam menentukan kegiatan produksi dengan menggunakan metode dan tahapan tertentu. Metode yang digunakan adalah *Double Exponential Smoothing*, *Neural Network* dan *ARIMA outlier* dalam memprediksi jumlah produksi teh pada tahun berikutnya. Hasil yang diperoleh yaitu metode yang paling baik digunakan untuk peramalan hasil produksi teh yaitu metode ARIMA. Hasil MSE yang dihasilkan bernilai sebesar 0.421757 dengan hasil peramalan yang diperoleh pada tahun 2018 tidak berbeda jauh dengan data actual pada tahun 2018 sehingga hasil prediksi dapat digunakan untuk prediksi tahun-tahun berikutnya dan dapat digunakan untuk menentukan jumlah produksi yang tepat untuk memenuhi kebutuhan pasar.

Kata kunci: *Double Exponential Smoothing*, *Neural Network*, *ARIMA outlier*, *Forecasting*, Perkebunan, Pertanian.

Abstract: The agricultural sector is one of the most important sectors in increasing economic development in Indonesia. The largest contributor to the surplus in the agricultural sector is the plantation sub-sector where tea is one of the leading commodities in it. So to meet a market need and improve the economy in Indonesia, it is necessary to have a plan in determining production needs appropriately. Of the many plantation crops that have many benefits, namely tea plantations. Tea plantations can be used as tourist attractions. In addition, every tea plantation must not escape the existence of a tea-making factory so that it produces a very diverse variety of tea products. The purpose of this research is to plan a required production activity whose name is prediction or forecasting which is an early stage as a basis for determining production activities using certain methods and stages. The method used is *Double Exponential Smoothing*, *Neural Network* and *ARIMA outlier* in predicting the amount of tea production in the following year. The result obtained is that the best method used for forecasting tea production is the ARIMA method. The MSE results generated are worth 0.421757 with the forecasting results obtained in 2018 not much different from the actual data in 2018 so that the prediction results can be used for predictions in the following years and can be used to determine the right amount of production to meet market needs.

Keyword: *Double Exponential Smoothing*, *Neural Network*, *ARIMA outlier*, *Forecasting*, *Plantation*, *Agriculture*.

1. Pendahuluan

Sektor pertanian menjadi salah satu sektor yang terpenting dalam meningkatkan pembangunan ekonomi di Indonesia. Penyumbang *surplus* terbesar dalam sektor pertanian yaitu subsektor perkebunan dimana teh merupakan salah satu komoditas yang menjadi unggulan didalamnya [1]. Sehingga untuk memenuhi suatu kebutuhan pasar dan meningkatkan perekonomian di Indonesia, diperlukan adanya rencana dalam menentukan kebutuhan produksi dengan tepat.

Untuk merencanakan suatu kegiatan produksi dibutuhkan yang namanya prediksi atau peramalan yang merupakan suatu tahap awal sebagai dasar dalam menentukan kegiatan produksi dengan menggunakan metode dan tahapan tertentu [3].

Penelitian sebelumnya yang juga membahas mengenai peramalan produksi telah dilakukan oleh [2] tentang perbandingan metode *Double Exponential Smoothing* dan *Last Square* dalam memprediksi jumlah produksi teh di salah satu perusahaan the di Blitar mendapatkan hasil bahwa metode *Least Square* lebih akurat dengan nilai MAPE sebesar 17,008% sedangkan nilai MAPE dari metode *Double Exponential Smoothing* yaitu sebesar 18,084%.

Berdasarkan referensi dari penelitian di atas, penelitian kali ini akan berfokus pada perbandingan metode menggunakan *Double Exponential Smoothing*, *Neural Network* dan *ARIMA outlier* dalam memprediksi jumlah produksi teh pada tahun berikutnya.

Penelitian ini bertujuan untuk mengetahui hasil peramalan produksi teh dengan metode yang paling sesuai sehingga dapat digunakan untuk kedepannya dalam memprediksi produksi teh dan dapat membantu dalam menentukan produksi yang tepat untuk memenuhi kebutuhan pasar.

2. Kajian Teori

a) Perkebunan

Perkebunan adalah segala bentuk kegiatan usaha tanaman tertentu pada tanah ataupun media tumbuh lainnya sesuai dengan ekosistem menggunakan bantuan teknologi dan pengetahuan untuk mewujudkan kesejahteraan bagi pelaku usaha dalam bidang perkebunan serta masyarakat luas [4]. Tanaman perkebunan sangat identik dengan komponen industri-industri besar dapat membuka lapangan pekerjaan dan bisa dijadikan sebagai sumber pendapatan negara (investasi modal dalam negeri ataupun luar negeri) yang dapat menjadikan produk dari hasil perkebunan ini berstandar internasional serta tujuan dari itu semua yaitu bisa ekspor di seluruh dunia. Macam-macam tanaman sektor perkebunan adalah kelapa sawit, kelapa, karet, teh, kopi dan kakao [5]. Dari banyaknya tanaman perkebunan yang terdapat banyak manfaatnya yaitu perkebunan teh. Perkebunan teh dapat dijadikan sebagai tempat wisata. Selain itu, di setiap perkebunan teh pasti tidak luput dari adanya pabrik pembuatan teh sehingga menghasilkan produk the yang sangat beragam macamnya [6].

b) Peramalan

Peramalan merupakan suatu kegiatan untuk memperkirakan atau memprediksi sebuah kejadian di masa mendatang didasarkan data di masa sebelumnya. Secara umum peramalan dibagi menjadi beberapa aspek sesuai dengan cara pandang setiap orang. Jika dikelompokkan maka peramalan terbagi menjadi tiga macam jenis yaitu peramalan menurut sifat penyusunannya, peramalan menurut jangka waktu ramalan dan peramalan menurut kategori jenis data yang digunakan [7].

c) *Double Exponential Smoothing* (DES)

Double Exponential Smoothing (DES) adalah salah satu metode dari *Exponential Smoothing* yang digunakan untuk peramalan dengan jangka waktu yang cukup panjang [8]. Metode ini dapat digunakan untuk data yang bersifat *stasioner*. Adapun parameter yang

digunakan yaitu α dan β . Kedua parameter tersebut merupakan kunci untuk penentuan model terbaik. Rumus metode DES yaitu :

$$S_i = (\alpha * X_i) + (1 - \alpha) * (S_{i-1} + b_{i-1}) \quad (1)$$

$$b_i = \beta * (S_i - S_{i-1}) + (1 - \beta) * b_{i-1} \quad (2)$$

Dimana :

X_i = Nilai peramalan periode ke-i

α = Parameter dengan nilai antara 0 sampai 1

S_i = Nilai pemulusan periode ke-i

S_{i-1} = Nilai pemulusan periode ke-i-1

β = Konstanta pembobot pemulusan ($0 < \beta < 1$)

b_i = Nilai smoothing unsur yang sama pada tahun ke-i

b_{i-1} = Nilai smoothing unsur yang sama pada tahun ke-i-1

d) **Artificial Neural Network (Jaringan Syaraf Tiruan)**

Artificial Neural Network merupakan sebuah model dalam komputasi yang fungsinya untuk meniru kegunaan dari system pada jaringan syaraf manusia. Model ini dapat dilakukan dengan proses training atau pembelajaran agar dapat menerima banyak stimulan atau rangsangan dari input data yang telah diinputkan [9]. Secara umum jaringan syaraf tiruan terdiri dari tiga lapisan yaitu pertama *Input Layer* sebagai input sejumlah informasi atau parameter, kedua *Hidden Layer* sebagai pengolahan data yang telah diinputkan sehingga memperoleh output dalam bentuk model untuk proses data baru dan ketiga *Output Layer* sebagai akhir dari proses data yang telah di-*training* sehingga menghasilkan bobot optimal [10].

e) **ARIMA Outlier**

ARIMA (*Autoregressive Integrated Moving Average*) adalah suatu metode peramalan yang sangat baik digunakan dalam jangka waktu pendek dikarenakan ketepatan peramalan kurang baik. Model ARIMA termasuk ke dalam Teknik pemodelan linear serta berasal dari AR (*Autoregressive*) differencing dan MA (*Moving Average*) [11]. Jika diklasifikasikan berdasarkan data ARIMA dibedakan menjadi dua diantaranya musiman dan non musiman. ARIMA non musiman disebut juga dengan metode runtun waktu Box-Jenkins yaitu analisis dalam permodelan ARIMA non musiman hingga tahap prediksi memakai metode dari Box-jenkins. Model ARIMA terbagi menjadi 3 tahap dasar yaitu identifikasi, penaksiran serta pengujian. Berikut merupakan tahapan pada metode ARIMA :

(1) **Model ARMA (p,q)**

Model ini adalah gabungan dari model AR (p) dan MA (q) sehingga terbentuk model campuran sebagai berikut [12] :

$$\begin{aligned} Y_t &= \phi Y_t - 1 + \dots + \phi_p Y_t - p + \alpha_t - \theta_1 \alpha_t - 1 - \dots - \theta_q \alpha \phi_p(B) \\ &= 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \\ \theta_q(B) &= 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \end{aligned} \quad (3)$$

yang dimaksud dengan model ARMA (p,q) dan bisa juga ditulis dalam bentuk:

$$\phi_p(B)y_t = \theta_q(B)\alpha_t \quad (4)$$

dengan:

Y_t : variable yang diramalkan

ϕ_1, \dots, ϕ_q : parameter *moving average*

ϕ_p : parameter autoregresif ke-p

B : operator *backshift*

(2) **Model ARIMA (p,d,q)**

Model ini merupakan model yang mengandung data yang tidak stasioner dikarenakan nilai rata-rata dan varians. Stasioneritas adalah dimana data pada nilai rata-rata tetap tidak bergantung terhadap waktu dan variansi itu sendiri [10].

a. Stasioner dalam variansi

Data dikatakan stasioner dalam variansi apabila data tersebut telah melalui tahap transformasi. Salah satu bentuk transformasi yang dapat dilakukan yaitu transformasi pangkat (*power transformation*) yang dikenalkan melalui Box dan Cox pada tahun 1964 dengan ketentuan sebagai berikut [13]:

$$Z'_t = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln(Z_t), & \lambda = 0 \end{cases} \quad (5)$$

dengan:

Z_t adalah data deret waktu periode ke- t

λ adalah parameter transformasi

b. Stasioner dalam rata-rata

Apabila terdapat data yang belum stasioner dalam rata-rata maka distasionerkan terlebih dahulu yaitu dengan melakukan cara *differencing* (pembedaan) agar memperoleh suatu model arima terbaik [14]. Metode *differencing* bisa didapatkan dengan cara mengurangi nilai pengamatan pada waktu t dengan nilai pengamatan pada waktu sebelumnya serta membentuk suatu data baru. Jika hasil *differencing* tersebut disimbolkan dengan W_t , maka secara umum *differencing* orde 1 dapat ditulis sebagai berikut:

$$\begin{aligned} W_t &= Z_t - Z_{t-1} \\ W_t &= (1 - B)Z_t \end{aligned} \quad (6)$$

dengan B adalah operator *backshift* (operator mundur).

Sedangkan *Outlier* merupakan nilai dari sebuah pengamatan yang tidak konsisten pada runtun waktu atau nilainya jauh berbeda dari data lainnya [15]. *Outlier* dapat menyebabkan analisis data yang dihasilkan tidak valid. Terdapat empat jenis *outlier* yaitu :

(1) *Innovational Outlier* (IO), adalah sebuah peristiwa yang berdampak terhadap proses ARIMA. Berikut ini bentuk umum *Innovational Outlier*

$$\begin{aligned} Z_t &= X_t + \frac{\theta(B)}{\theta(B)} \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} (\alpha_t + \omega I_t^{(T)}) \end{aligned} \quad (7)$$

(2) *Additive Outlier* (AO), adalah sebuah peristiwa yang berdampak terhadap data time series hanya pada satu periode saja yaitu pengamatan ke-T. berikut ini bentuk umum *Additive Outlier*

$$\begin{aligned} Z_t &= \begin{cases} X_t & t \neq T \\ X_t + \omega & t = T \end{cases} \\ &= X_t + \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} \alpha_t + \omega I_t^{(T)} \end{aligned} \quad (8)$$

dimana

$I_t^{(T)} = \begin{cases} 1 & t = T \\ 0 & t \neq T \end{cases}$ merupakan variable indikator yang mewakili ada atau tidak *outlier* pada waktu T.

- (3) *Temporary Change* (TC), adalah sebuah peristiwa dimana *outlier* menghasilkan efek awal sebesar ω pada waktu t , lalu secara perlahan sesuai dengan besarnya δ . Berikut ini bentuk umum *Temporary Change*

$$Z_t = X_t + \frac{1}{(1-\delta B)} \omega I_t^{(T)} \quad (9)$$

- (4) *Level Shift* (LS), adalah peristiwa yang berdampak terhadap deret waktu tertentu yang memberikan suatu perubahan secara tiba-tiba sehingga mengakibatkan bersifat permanen. Berikut ini bentuk umum *Level Shift*

$$Z_t = X_t + \frac{1}{(1-B)} \omega I_t^{(T)} \quad (10)$$

Jika $\delta = 0$ maka TC akan menjadi kasus *additive outlier*, sedangkan pada saat $\delta = 1$ maka TC akan menjadi kasus *level shift*

f) *Mean Square Error* (MSE)

Mean Square Error (MSE) digunakan untuk mengukur kesalahan peramalan keseluruhan nilai dugaan model yang dinyatakan dalam rata-rata dari kuadrat kesalahan [16] :

$$MSE = \frac{\sum (X_t - F_t)^2}{n} \quad (11)$$

- X_t : data sebenarnya terjadi
 F_t : data ramalan dihitung dari model yang akan digunakan pada waktu ke- t
 n : banyak data

3. Metode Penelitian

Pada penelitian kali ini digunakan data sekunder yang diambil dari laman bps.go.id yang berupa data produksi dari perkebunan teh mulai pada bulan Januari tahun 2014 sampai dengan bulan Desember 2017 dengan menggunakan pembagian data *training* sebesar 80% dan *testing* sebesar 20%. Data aktual produksi teh dapat dilihat pada tabel 1 sebagai berikut.

Tabel 1. Data Produksi Teh

Tahun	Jan	Feb	Mar	Apr	Mei	Jun	Jul	Ags	Sep	Okt	Nov	Des
2014	8.69	7.86	9.36	9.29	9.56	8.63	8.22	8.12	7.97	8.42	8.61	8.78
2015	7.60	6.40	6.73	8.53	7.86	7.77	6.47	6.84	6.32	6.18	5.94	6.51
2016	8.58	7.57	7.68	8.40	7.85	7.60	7.26	7.48	6.92	7.06	7.13	7.54
2017	7.73	7.28	7.14	8.06	8.08	6.93	8.20	7.11	6.88	7.77	8.29	8.46

Diketahui dari data di atas bahwa produksi dari perkebunan teh tidak mengalami perbedaan yang cukup signifikan atau dapat dikatakan bahwa data termasuk ke dalam data *stasioner*. Sehingga beberapa metode yang dapat digunakan dalam penelitian ini yaitu *Double Exponential Smoothing*, *Neural Network* dan *ARIMA Outlier*

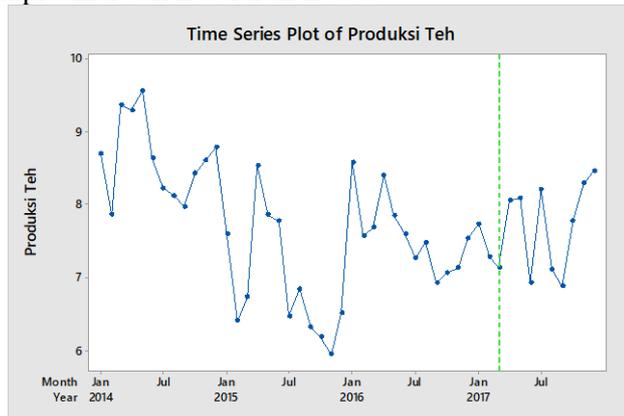
Untuk melakukan peramalan menggunakan metode-metode tersebut terdapat beberapa langkah analisis yang harus dilakukan yaitu sebagai berikut.

- 1) Melakukan pembagian data *training* dan *testing* dari data aktual dan dilakukan plotting data
- 2) Melakukan proses forecasting dan menghitung nilai MSE menggunakan metode *Double Exponential Smoothing*
- 3) Melakukan proses forecasting dan menghitung nilai MSE menggunakan metode *Neural Network*
- 4) Melakukan proses forecasting dan menghitung nilai MSE menggunakan metode *ARIMA Outlie*, dengan langkah-langkah:4
 - a) Mengecek kestasioneritasan dalam varians dan mean
 - b) Melakukan dugaan model AR, MA dan ARMA dan mengecek signifikasi serta tes normalitas
 - c) Melakukan forecasting pada model terbaik.

- 5) Membandingkan kebaikan model untuk dilakukan forecasting dengan melihat nilai kriteria MSE pada setiap metode

4. Hasil dan Pembahasan

Berdasarkan data yang telah diperoleh, kemudian data dilakukan pembagian menjadi data *training* sebesar 80% dan *testing* sebesar 20% dimana data training nanti akan digunakan untuk mencari model terbaik dan data testing untuk menguji model tersebut yang nantinya akan digunakan untuk memprediksi dari keseluruhan data.

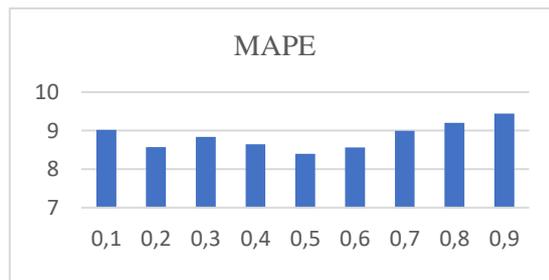


Gambar 1. Plot Time Series Pemisahan antara data Training dan Testing

Pada gambar 1 terlihat pola data pada produksi teh yaitu stasioner, kemudian pembagian data training diambil dari data awal mulai dari bulan Januari 2014 hingga Februari 2017 seangkan untuk data testing yaitu sisanya. Pemisahan antara data training dan testing ditandai dengan garis vertikal putus-putus berwarna hijau.

4.1. Metode Double Exponential Smoothing

Untuk menentukan hasil peramalan menggunakan *Double Exponential Smoothing* terlebih dahulu digunakan penentuan model menggunakan data *training* dengan mencari nilai error terendah dari setiap nilai konstanta α dan β antara 0,1 sampai dengan 0,9 seperti berikut.



Gambar 2. Grafik nilai MAPE

Berdasarkan grafik pada gambar 2 diketahui bahwa nilai MAPE terendah terletak pada nilai konstanta α dan $\beta = 0,5$ sehingga dapat dilanjutkan untuk menguji model terbaik pada Metode *Double Exponential Smoothing* yaitu pada konstanta α dan $\beta = 0,5$ menggunakan data *testing* dengan hasil error sebagai berikut.

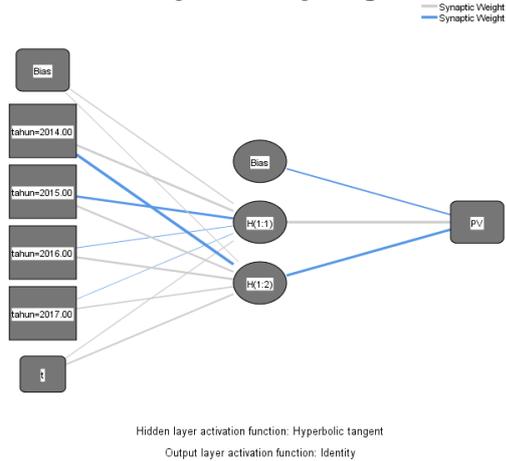
Tabel 2. Nilai error data *testing*

MAPE	9.12401
MAD	0.69319
MSD	0.58066

4.2. Metode Neural Network

Untuk melakukan peramalan menggunakan Neural Network dilakukan penambahan variabel baru yang mempengaruhi data yaitu variabel tahun dan variabel t dimana masing-masing dari ke-tiga variabel tersebut untuk variabel data aktual akan dimasukkan ke dalam *Dependent Variable*, variabel tahun dimasukkan ke dalam *Factors*, dan variabel t dimasukkan ke dalam *Covariate* dengan menggunakan nilai data training dan testing sebesar 80% dan 20% .

Kemudian didapatkan hasil optimum model yaitu dengan hidden input sebanyak 5 dan hidden layers sebanyak 2 menggunakan aktivasi model *Hyperbolic Tangent*. Gambar pemetaan arsitektur neural network dapat dilihat pada gambar 3 sebagai berikut.



Gambar 3. Arsitektur Neural Network

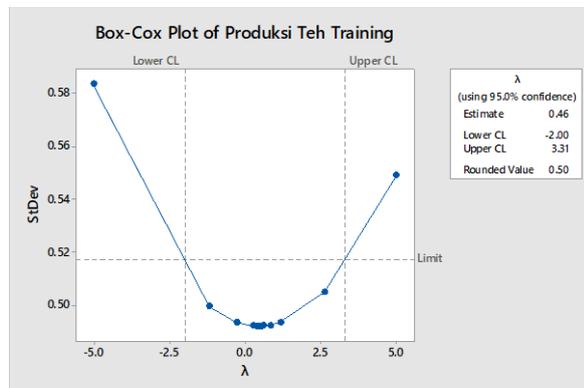
Dari pemetaan pada gambar 3 di atas di dapatkan nilai error terhadap masing-masing data training dan testing yaitu sebagai berikut.

Tabel 3. Nilai error data *training* dan *testing*

Training		Testing	
MSE	Relative Error	MSE	Relative Error
10,751	0,551	2,185	0,386

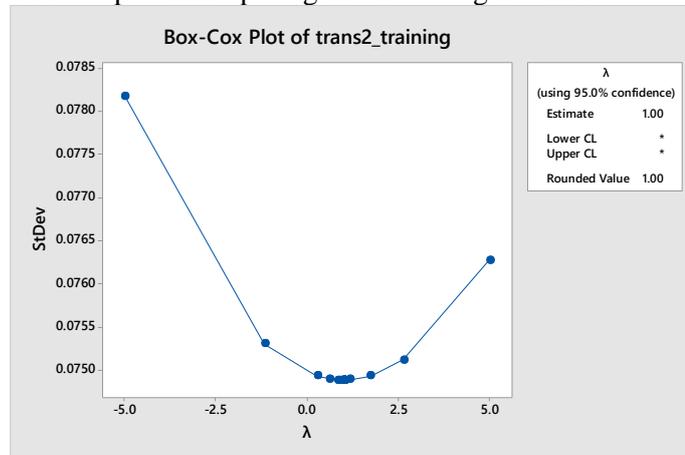
4.3. Metode ARIMA Outlier

Dalam peramalan menggunakan metode ARIMA langkah awal yang harus dilakukan yaitu melakukan pengecekan kestasioneritasan terhadap varians dan mean dengan menggunakan data training. Untuk mengecek kestasioneritasan terhadap varians dapat dilihat pada hasil *Box Cox Plot* dengan ketentuan jika nilai *p-value* = 1 atau nilai *Lower Upper* > 1.



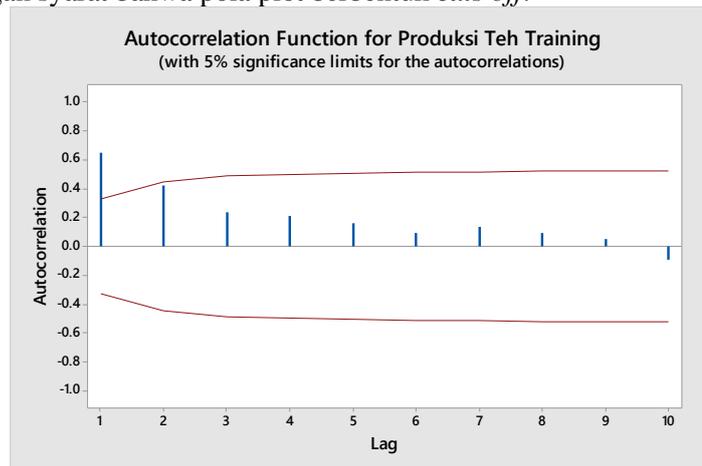
Gambar 4. Box Cox Plot

Dari hasil pada gambar 4 didapatkan hasil bahwa data belum stasioner terhadap varians sehingga harus dilakukan transformasi hingga mendapatkan hasil data telah stasioner terhadap varians. Setelah dilakukan perhitungan didapatkan hasil bahwa data telah stasioner terhadap varians setelah dilakukan 2 kali transformasi dengan nilai rounded value sebesar 1. Hasil Box Cox Plot dapat dilihat pada gambar 5 sebagai berikut.



Gambar 5. Box Cox Plot Stasioner terhadap varians

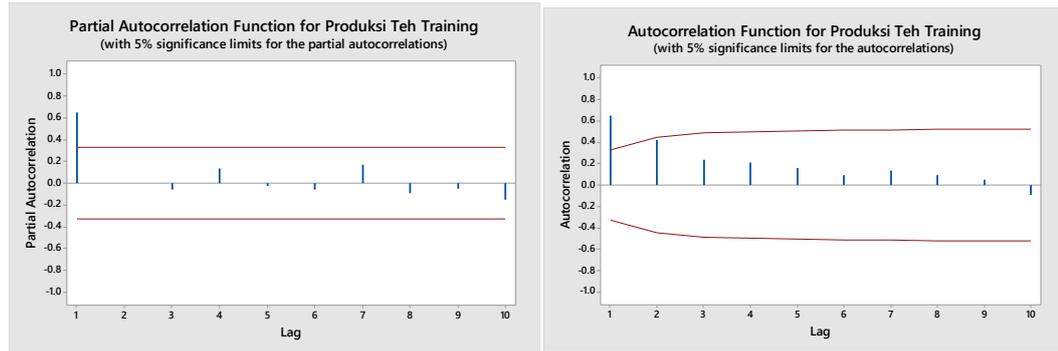
Selanjutnya untuk mengecek kestasioneritasan terhadap mean dapat dilihat pada hasil plot ACF dengan syarat bahwa pola plot berbentuk *cuts off*.



Gambar 6. Plot ACF

Pada gambar 6 diketahui bahwa pola plot termasuk ke dalam pola *cuts off* (turun cepat), sehingga data sudah dapat dikatakan stasioner terhadap mean.

Setelah dilakukan cek stasioneritas varians dan mean dapat dilanjutkan dengan menentukan dugaan model AR, MA dan ARMA. Untuk model AR dapat ditentukan dengan melihat plot PACF yaitu jika lag pertama dari hasil plot tersebut keluar maka model dugaannya yaitu AR (1,0,0), sedangkan untuk menentukan model MA ditentukan dengan melihat plot ACF dengan syarat yang sama dengan penentuan model AR yaitu jika lag pertama dari hasil plot tersebut keluar maka model dugaannya yaitu MA (0,0,1), dan yang terakhir yaitu dugaan model sempurna ARMA didapat dari gabungan model AR dan MA sehingga model dugaannya yaitu ARMA (1,0,1).



Gambar 7. Plot PACF dan ACF

Berdasarkan hasil plot pada gambar 7 didapatkan hasil bahwa data menggunakan model dugaan AR (1,0,0), MA (0,0,1) dan ARMA (1,0,1).

Kemudian masing-masing di signifikansi serta tes normalitas didapatkan hasil bahwa model ARMA tidak signifikan sehingga tidak dapat digunakan sebagai model. Sedangkan model AR (1,0,0) dan MA (0,0,1) signifikan dan berdistribusi normal sehingga model tidak terdapat outlier. Maka model yang dapat digunakan yaitu AR (1,0,0) dan MA (0,0,1) tanpa outlier, yang akan ditentukan model terbaik melalui nilai MSE terkecil.

Tabel 4. Nilai error model

Model	MSE
AR (1,0,0)	0.477999
MA (0,0,1)	0.566718

Dari hasil MSE pada tabel 4 didapatkan hasil terbaik yaitu pada model AR (1,0,0) yang kemudian dapat dilanjutkan dengan menguji model AR (1,0,0) terhadap data testing dan didapatkan hasil nilai MSE yaitu 0.421757.

4.4. Penentuan metode Terbaik untuk melakukan Forecasting

Dalam menentukan metode terbaik yang akan digunakan dalam prediksi hasil produksi teh pada tahun berikutnya yaitu tahun 2018 yaitu dengan melakukan perbandingan nilai error masing-masing metode menggunakan MSE pada data testing yaitu sebagai berikut.

Tabel 5. Nilai MSE masing-masing metode

Metode	MSE
Double Exponential Smoothing (DES)	0.58066
Neural Network (NN)	2,185
ARIMA Outlier	0.421757

Sehingga dari hasil pada tabel 5 di atas diketahui bahwa metode ARIMA merupakan metode terbaik dengan nilai MSE paling kecil.

4.5. Peramalan

Karena metode ARIMA merupakan metode terbaik pada penelitian ini maka hasil peramalan akan menggunakan model ARIMA yang kemudian dibandingkan data sebenarnya pada tahun 2018 dengan hasil yaitu sebagai berikut.

Tabel 5. Nilai MSE masing-masing metode

Bulan	Hasil Forecast
Januari (2018)	8.19168
Februari (2018)	8.02570
Maret (2018)	7.92303
April (2018)	7.85952
Mei (2018)	7.82024
Juni (2018)	7.79594
Juli (2018)	7.78090
Agustus (2018)	7.77161

Bulan	Hasil Forecast
September (2018)	7.76585
Oktober (2018)	7.76230
November (2018)	7.76010
Desember (2018)	7.75873

Hasil prediksi tersebut dapat digunakan untuk menentukan jumlah produksi yang tepat untuk memenuhi kebutuhan pasar di tahun-tahun berikutnya untuk memaksimalkan keuntungan (*profit*).

5. Simpulan

Dari perbandingan 3 metode yaitu *Double Exponential Smoothing*, *Neural Network* dan *ARIMA Outlier* didapatkan metode yang terbaik yaitu metode ARIMA dengan hasil uji tes normalitas didapatkan hasil bahwa model ARMA tidak signifikan sehingga tidak dapat digunakan sebagai model. Sedangkan model AR (1,0,0) dan MA (0,0,1) signifikan dan berdistribusi normal sehingga model tidak terdapat outlier. Maka model yang dapat digunakan yaitu AR (1,0,0) dan MA (0,0,1) tanpa *outlier*, yang akan ditentukan model terbaik melalui nilai MSE terkecil sebesar 0.421757 yaitu pada model AR (1,0,0) terhadap data *outlier*. Hasil peramalan yang diperoleh pada tahun 2018 tidak berbeda jauh dengan data aktual pada tahun 2018 sehingga hasil prediksi dapat digunakan untuk prediksi tahun-tahun berikutnya dan dapat digunakan untuk menentukan jumlah produksi yang tepat untuk memenuhi kebutuhan pasar.

Daftar Pustaka

- [1] M. Arrazy and R. Primadini, "Proyeksi Ekspor Teh Indonesia dengan Metode ARIMA," vol. 3, no. 1, pp. 30–52, 2020.
- [2] M. B. Nurkahfi, V. Wahanggara, and B. H. Prakoso, "Perbandingan Metode Double Exponential Smoothing dan Least Square untuk Sistem Prediksi Hasil Produksi Teh," *BIOS J. Teknol. Inf. dan Rekayasa Komput.*, vol. 1, no. 2, pp. 48–53, 2021, doi: 10.37148/bios.v1i2.12.
- [3] R. Hardianto and Zulhamidi, "Peramalan Penjualan Teh Hijau dengan Metode ARIMA (Studi Kasus pada PT. MK)," vol. XI, no. 3, pp. 231–244, 2016.
- [4] J. Lawendatu, J. S. Kekenusa, and D. Hatidja, "Regresi Linier Berganda Untuk Menganalisis Pendapatan Petani Pala," *d'CARTESIAN*, vol. 3, no. 1, p. 66, 2014, doi: 10.35799/dc.3.1.2014.3998.
- [5] J. B. Basrawi, "Model Internalisasi Nilai-nilai Akhlak pada Keluarga Buruh Perkebunan Teh," *Golden Age J. Pendidik. Anak Usia Dini*, vol. 3, no. 1, pp. 56–63, 2019, doi: 10.29313/ga.v3i1.4834.
- [6] R. W. Apsari, E. N. Billah, and N. Insani, "Dampak Covid-19 Terhadap Pengelolaan Agrowisata Perkebunan Teh Sirah Kencong Kabupaten Blitar sebagai Obyek Wisata Berkelanjutan," vol. 02, no. 02, pp. 61–72, 2020.
- [7] M. Arumsari and A. Dani, "Peramalan Data Runtun Waktu menggunakan Model Hybrid Time Series Regression – Autoregressive Integrated Moving Average," *J. Siger Mat.*, vol. 2, no. 1, pp. 1–12, 2021, doi: 10.23960/jsm.v2i1.2736.
- [8] A. E. Armi, A. H. Kridalaksana, and Z. Arifin, "Peramalan Angka Inflasi Kota Samarinda Menggunakan Metode Double Exponential Smoothing (Studi Kasus : Badan Pusat Statistik Kota Samarinda)," *Inform. Mulawarman J. Ilm. Ilmu Komput.*, vol. 14, no. 1, p. 21, Feb. 2019, doi: 10.30872/jim.v14i1.1252.
- [9] F. G. S. Sitio, R. A. Primardhi, and B. A. Pramudita, "Rancang Bangun Sistem Pengukuran Intensitas Hujan Sebagai Early Warning System Hama Pada Tanaman Teh Berbasis Internet of (Design and Development of Rain Intensity Measurement System As Early Warning System for Pests on Tea Plant Based on Internet of Thi," *Univ. Telkom*, vol. 8, no. 5, pp.

- 4512–4520, 2021.
- [10] S. M. Robial, “Perbandingan Model Statistik pada Analisis Metode Peramalan Time Series (Studi Kasus: PT. Telekomunikasi Indonesia, Tbk Kandatel Sukabumi),” *J. Ilm. SANTIKA*, vol. 8, no. 2, pp. 1–17, 2018.
- [11] N. Salwa, N. Tatsara, R. Amalia, and A. F. Zohra, “Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average),” vol. 1, no. 1, pp. 21–31, 2018.
- [12] J. Tando, H. Komalig, N. Nainggolan, and M. B. Port, “Prediksi Jumlah Penumpang Kapal Laut di Pelabuhan Laut Manado Menggunakan Model ARMA Employing ARMA Methods to Predict The Number of Ships Passanger at,” 2015.
- [13] J. U. Meramalkan, “Aplikasi Metode Arima Box-,” doi: 10.20473/ijph.v113i1.2018.181-194.
- [14] L. Novamizanti, G. Budiman, and B. A. D. I. Wibowo, “Optimasi Sistem Penyembunyian Data pada Audio menggunakan Sub-band Stasioner dan Manipulasi Rata-rata Statistik,” vol. 6, no. 2, pp. 165–179, 2018.
- [15] J. Gaussian, “1 , 2 , 3 1,” vol. 2, no. January 2006, pp. 39–48, 2013.
- [16] S. Susilawati and M. Muhathir, “Analisis Pengaruh Fungsi Aktivasi, Learning Rate Dan Momentum Dalam Menentukan Mean Square Error (MSE) Pada Jaringan Saraf Restricted Boltzmann Machines (RBM),” *J. Informatics Telecommun. Eng.*, vol. 2, no. 2, p. 77, 2019, doi: 10.31289/jite.v2i2.2162.