

PERAMALAN PRODUKSI CABE BESAR DAN CABE RAWIT DI KALIMANTAN TENGAH DENGAN METODE ARIMA

*Forecasting of Chilli and Small Chilli Production in Central Kalimantan
Using ARIMA Method*

Frits Fahridws Damanik

Statistisi Muda pada BPS Kota Tebing Tinggi
Alamat : Tebing Tinggi, Tanjung Marulak, Tebing Tinggi City
corresponding author: frits.damanik@bps.go.id

(Dikirim 14-12-2019; Diterima 30-12-2019)

ABSTRACT

Chili is one of the leading commodities of vegetables which has strategic value at national and regional levels. An unexpected increase in chili prices often results a surge of inflation and economic turmoil. Study and modeling of chili production are needed as a planning and evaluation material for policy makers. One of the most frequently used methods in modeling and forecasting time series data is Autoregressive Integrated Moving Average (ARIMA). The results of ARIMA modeling on chili production data found that the data were unstationer conditions of the mean so that must differenced while the data on the production of small chilli carried out the stages of data transformation and differencing due to the unstationer of data on variants and the mean. The best ARIMA model that can be applied based on the smallest AIC and MSE criteria for data on the amount of chili and small chilli production in Central Kalimantan Province is ARIMA (3,1,0).

Keywords: modeling of chilli, forecasting of chilli, Autoregressive Integrated Moving Average, ARIMA, Box-Jenkins.

ABSTRAK

Cabai merupakan salah satu komoditas unggulan sayuran yang sangat bernilai strategis baik di level nasional maupun daerah. Kenaikan harga cabai yang tidak terduga sering mengakibatkan lonjakan inflasi yang berakibat pada kekacauan perekonomian. Kajian dan pemodelan terhadap produksi cabai diperlukan sebagai bahan perencanaan dan evaluasi bagi para pengambil kebijakan. Salah satu metode yang paling sering digunakan dalam melakukan pemodelan dan peramalan terhadap data *time series* adalah *Autoregressive Integrated Moving Average* (ARIMA). Hasil pemodelan ARIMA pada data produksi cabai besar menemukan kondisi ketidakstasioneran data terhadap mean sehingga dilakukan tahapan *differencing* sedangkan pada data produksi cabai rawit dilakukan tahapan transformasi data dan differencing diakibatkan ketidakstasioneran data terhadap varian dan mean. Model ARIMA terbaik yang dapat diterapkan berdasarkan kriteria AIC dan MSE terkecil terhadap data jumlah produksi cabai besar dan cabai rawit di Provinsi Kalimantan Tengah adalah ARIMA(3,1,0).

Kata kunci: pemodelan cabai, peramalan cabai, *Autoregressive Integrated Moving Average*, ARIMA, Box-Jenkins.

PENDAHULUAN

Cabai merupakan salah satu komoditas unggulan sayuran semusim di Indonesia. Pada tahun 2018, produksi cabai besar sebesar 1,21 juta ton sedangkan cabai rawit mencapai 1,34 juta ton (BPS, 2019). Besarnya konsumsi masyarakat terhadap cabai sebagai pelengkap kebutuhan memasak sehari-hari menjadikan komoditas ini sebagai salah satu komoditas yang berperan strategis di level nasional. Kenaikan harga cabai akibat kurangnya pasokan di pasar sering kali menyebabkan gejolak inflasi yang tinggi dan berdampak kepada perekonomian daerah bahkan nasional. Kurangnya pasokan cabai ini disebabkan banyak faktor diantaranya penurunan luas tanam cabai, gagal panen akibat hama ataupun perubahan musim dan juga ulah para tengkulak cabai yang melakukan penimbunan khususnya pada menjelang hari-hari besar. Fenomena kelangkaan dan kenaikan harga cabai ini terjadi secara nasional termasuk di Kalimantan Tengah. Kurangnya pasokan cabai dari produksi lokal akan menyebabkan meningkatnya jumlah impor dari luar daerah. Berbagai analisis dan kajian terhadap jumlah produksi lokal dari komoditas cabai sangat diperlukan sebagai bahan evaluasi dan kebijakan dalam menjaga stabilitas perekonomian daerah khususnya di Kalimantan Tengah. Salah satu metode analisis yang dapat digunakan untuk memodelkan dan meramalkan produksi cabai adalah dengan metode *Autoregressive Integrated Moving Average* (ARIMA). ARIMA merupakan salah satu metode yang paling sering digunakan untuk melakukan analisis runtun waktu. Dalam prosesnya, ARIMA menggunakan nilai masa lalu dan sekarang dari suatu variabel untuk menghasilkan peramalan jangka pendek yang akurat.

Beberapa peneliti yang menggunakan metode ARIMA dalam peramalan komoditas cabai antara lain: Karima (2018) meramalkan produksi cabai besar di Indonesia dengan menggunakan metode *Seasonal ARIMA*, Abinowi (2018) meramalkan curah hujan, produksi dan kebutuhan cabai dengan menggunakan metode ARIMA dan *Intervention Model*, Perihatini, dkk (2018) meramalkan harga cabai merah keriting di Kabupaten Banyumas dengan Menggunakan metode ARIMA *Box-Jenkins*, Nabilah (2017) meramalkan harga dan produksi cabe rawit di Provinsi Jawa Timur dengan metode ARIMA *Box-Jenkins*, Hadiansyah (2017) memprediksi harga cabai di Indonesia dengan pemodelan *time series* ARIMA.

METODE PENELITIAN

Model ARIMA dibangun dari 3 (tiga) proses, yaitu: proses *Autoregressive*, proses *Integrated* dan proses *Moving Average*.

1. Proses *Autoregressive* (Proses AR)

Proses *autoregressive* sesuai dengan namanya adalah proses hasil regresi dengan dirinya sendiri. Secara matematis proses AR(p) dapat dituliskan:

$$\phi_p(B)Y_t = a_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Y_t = a_t$$

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t$$

yang menunjukkan bahwa nilai saat ini merupakan jumlah tertimbang dari nilai-nilai p yang lalu ditambah satu error yang random saat ini.

2. Proses *Moving Average* (Proses MA)

Yaitu proses *time series* di mana nilai suatu data *time series* pada suatu waktu merupakan fungsi dari *error/residual* pada waktu-waktu sebelumnya. Secara matematik proses MA (q) dapat dituliskan sebagai berikut :

$$Y_t = \theta_q(B)a_t$$

$$Y_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)a_t$$

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

3. Proses *Autoregressive Integrated Moving Average* (Proses ARMA)

Secara matematik model ARMA (p,q) dapat dituliskan sebagai berikut:

$$\phi_p(B)Y_t = \theta_q(B)a_t$$

Adapun proses *differencing/integrated* dapat dituliskan sebagai berikut:

$$(1 - B)^d Y_t = \omega_t$$

dimana d menunjukkan derajat *differencing*.

Bila ketiga proses *time series* dilakukan penggabungan, maka proses *time series* tersebut disebut dengan proses *Autoregressive Integrated Moving Average* atau disingkat dengan ARIMA. Persamaan model ARIMA (p,d,q) dapat diturunkan sebagai berikut:

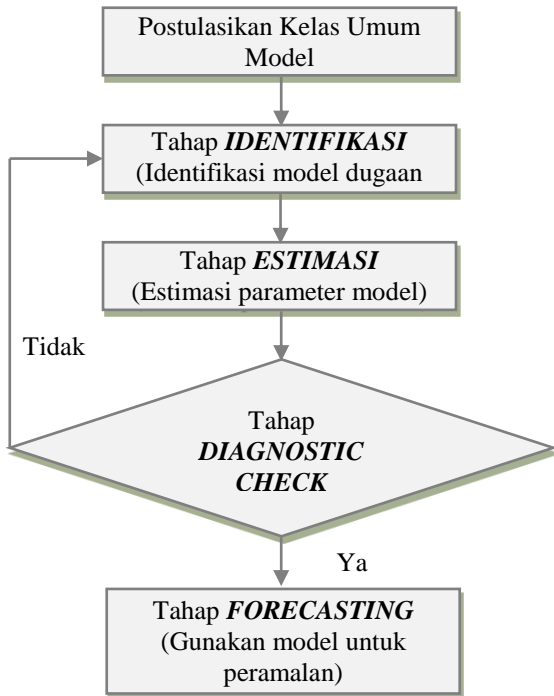
$$\phi_q(B)(1 - B)^d Y_t = \theta_q(B)a_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d Y_t =$$

$$(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)a_t$$

Metode ARIMA yang mengikuti prosedur Box-Jenkins (1970) mempunyai 4 (empat) tahapan yaitu: identifikasi, estimasi, *diagnostic check* dan *forecasting*.


Proses iteratif terjadi pada tahap *diagnostic check*. Bila pada tahap ini, uji parameter dan uji asumsi tidak terpenuhi maka tahapan kembali pada tahap pertama yaitu identifikasi.



Gambar 1. Tahapan Iteratif Box-Jenkins Untuk Pembentukan Model
 Suhartono, 2009

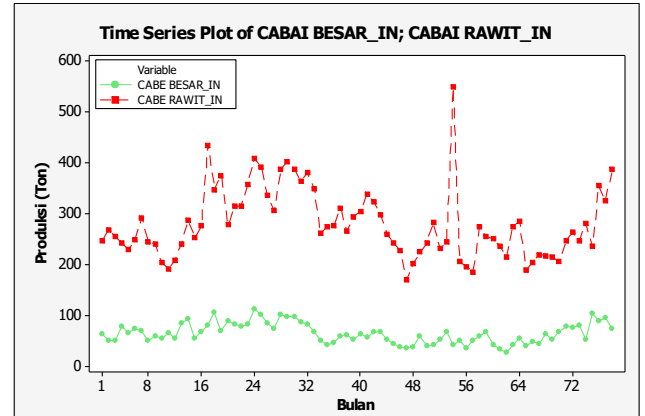
HASIL DAN PEMBAHASAN

Secara kasat mata terlihat pada Gambar 2 bahwa produksi cabai rawit di Kalimantan Tengah jauh lebih besar dibandingkan dengan produksi cabai merah pada periode Januari 2012-Desember 2018. Selain itu, produksi cabai rawit terlihat lebih berfluktuatif dibandingkan dengan produksi cabai besar yang terlihat lebih landai pada gambar.



Gambar 2. Produksi Cabai Besar dan Cabai Rawit, Jan 2012-Des 2018 (ton)

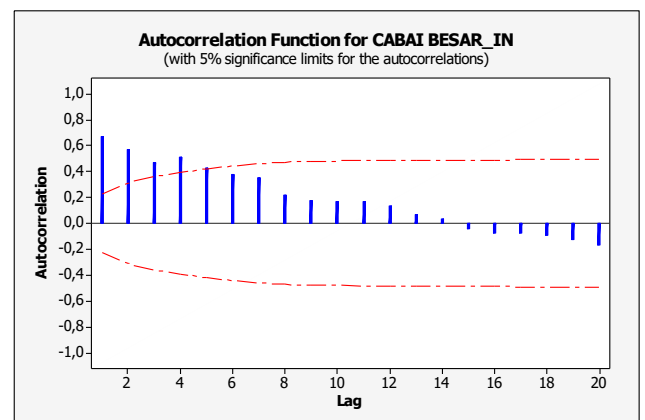
Pada metode ARIMA ini data akan dibagi menjadi 2 bagian dimana data dari Januari 2012-Juni 2018 menjadi data *in-sample* dan data Juli-Desember 2018 menjadi data *out-sample*.



Gambar 3. Time Series Plot Data in sample Produksi Cabai Besar dan Cabai Rawit

Dari plot *time series* data *in-sample* pada gambar 3 terlihat pola data produksi cabai rawit sangat berfluktuatif dan jelas diduga belum stasioner terhadap mean sehingga perlu dilakukan *differencing*. Adapun untuk produksi cabai besar perlu alat bantu lain untuk memastikan apakah data sudah stasioner atau belum. Salah satu alat bantu untuk melihat kestasioneran data adalah dengan melihat pola yang dibentuk dari fungsi autokorelasi (ACF). Ketidakstasioneran data dapat terlihat dari bentuk *corregram*-nya.


Dari plot ACF data produksi cabai besar pada gambar 4 terlihat bahwa pola ACF menurun lambat antar *lag*-nya yang menandakan bahwa data belum stasioner terhadap mean sehingga perlu dilakukan tahapan *differencing*.



Gambar 4. ACF Data in sample Produksi Cabai Besar

Gambar 5 menunjukkan plot data setelah dilakukan *differencing* dan terlihat nilai-nilai observasi


berada pada sekitar mean yang berindikasi data sudah stasioner.



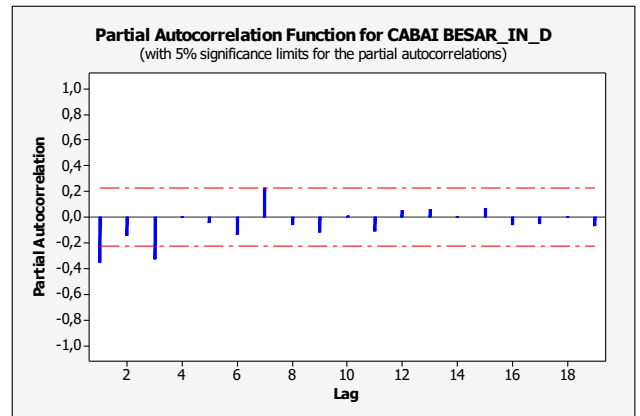
Gambar 5. Time Series Plot Data in sample Produksi Cabai Besar dan Cabai Raw Differencing 1

Setelah memastikan bahwa pola data observasi sudah stasioner maka langkah selanjutnya adalah melihat kembali plot ACF data beserta Partial Autocorrelation Function (PACF)-nya agar dapat melakukan pendugaan model sementara.

Dari plot ACF cabai besar pada gambar 6 terlihat bahwa pada lag 1 cut-off dan turun secara sinusoidal pada lag berikutnya sehingga menunjukkan terjadinya proses MA murni sedangkan plot PACF pada gambar 7 memperlihatkan adanya cut-off pada lag 1 dan 3 yang menunjukkan adanya proses AR murni.

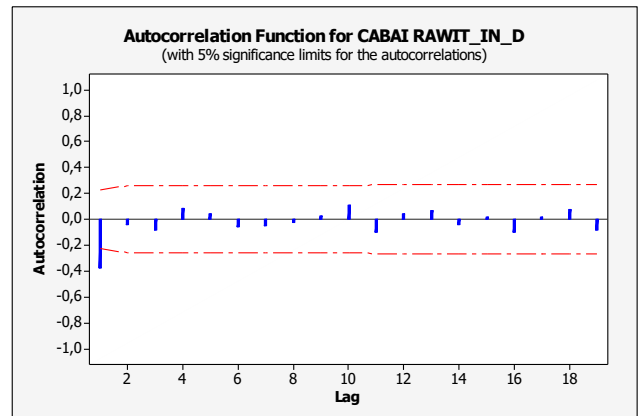


Gambar 6. ACF Data in sample Produksi Cabai Besar Differencing 1




Gambar 7. PACF Data in sample Produksi Cabai Besar Differencing 1

Berdasarkan plot ACF dan PACF cabai besar tersebut maka dugaan awal model ARIMA yang terbentuk yaitu: ARIMA(3,1,0), ARIMA([1,3],1,0) dan ARIMA(0,1,1). Dengan tahapan yang sama, berdasarkan gambar 8 dan 9 maka dapat dibuat pula dugaan model awal ARIMA untuk cabai rawit yaitu ARIMA(3,1,0) dan ARIMA(0,1,1).



Gambar 8. ACF Data in sample Produksi Cabai Rawit Differencing 1



Gambar 9. PACF Data in Sample Produksi Cabai Rawit Differencing 1

Langkah selanjutnya adalah melakukan estimasi parameter model dugaan sekaligus melakukan

diagnostic check dan melakukan dugaan-dugaan model lain jika asumsi belum terpenuhi.

Tabel 1. Estimasi dan Signifikansi Parameter Model Dugaan pada Data *in sample* Produksi Cabai Besar Differencing 1

Parameter	Estimasi/p-values Model Dugaan		
	ARIMA (3,1,0)	ARIMA ([1,3],1,0)	ARIMA (0,1,1)
ϕ_1	-0.46493/ ($<.0001$)	-0.36277/ (0.0010)	
ϕ_2	-0.28514/ (0.0184)	-0.24068/ (0.0265)	
ϕ_3	-0.34287/ (0.0029)		
θ_1			0.54509/ ($<.0001$)

Tabel 2. Uji *White Noise* dan Kenormalan Residual Model Dugaan pada Data *in sample* Produksi Cabai Besar Differencing 1

Uji White Noise dan Kenormalan Residual	Model Dugaan		
	ARIMA (3,1,0)	ARIMA ([1,3],1,0)	ARIMA (0,1,1)
Lag			
6	0.7965	0.0647	0.4254
12	0.5489	0.0809	0.5230
18	0.8819	0.3457	0.8614
24	0.9289	0.5719	0.8953
Test			
Normalitas			
Kolmogorov-Smirnov	>0.1500	>0.1500	>0.1500
Kesimpulan	WN/ Normal	WN/ Normal	WN/ Normal

Tabel 3. Perbandingan Nilai AIC dan MSE Model ARIMA Produksi Cabai Besar

Model	<i>In-sample</i> AIC	<i>Out-sample</i> MSE
ARIMA (3,1,0)	631.11	493.8346
ARIMA ([1,3],1,0)	634.9346	523.3355
ARIMA (0,1,1)	632.4465	541.3895

Berdasarkan hasil olah data terlihat pada Tabel 1 bahwa hasil estimasi parameter untuk semua model signifikan dan Tabel 2 menunjukkan hasil *diagnostic check* ketiga model dugaan sudah *White Noise* dan berdistribusi normal. Untuk menentukan model terbaik yang akan digunakan untuk melakukan peramalan produksi cabai besar digunakan kriteria nilai AIC

terkecil pada data *in-sample* serta MSE terkecil pada data *out-sample*. Berdasarkan perbandingan pada Tabel 3 terlihat bahwa model ARIMA terbaik adalah ARIMA (3,1,0).

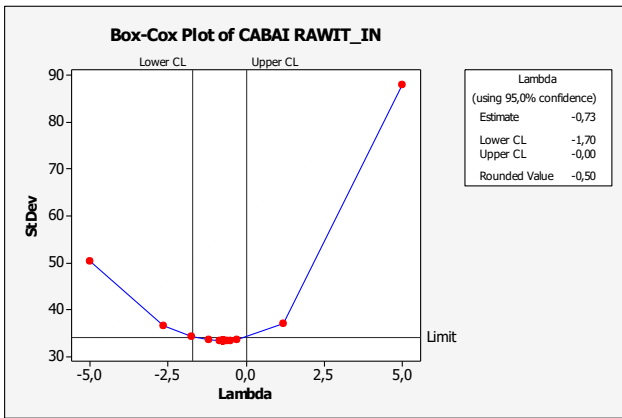
Tabel 4. Estimasi dan Signifikansi Parameter Model Dugaan pada Data *in sample* Produksi Cabai Rawit Differencing 1

Parameter	Estimasi/p-values Model Dugaan	
	ARIMA (3,1,0)	ARIMA (0,1,1)
ϕ_1	-0.51615/ ($<.0001$)	
ϕ_2	-0.32834/ (0.0091)	
ϕ_3	-0.25158/ (0.0338)	
θ_1		0.62415/ ($<.0001$)

Tabel 5. Uji *White Noise* dan Kenormalan Residual Model Dugaan pada Data *in sample* Produksi Cabai Rawit Differencing 1


Uji White Noise dan Kenormalan Residual	Model Dugaan	
	ARIMA (3,1,0)	ARIMA (0,1,1)
Lag		
6	0.6549	0.7902
12	0.8351	0.8889
18	0.9327	0.9374
24	0.8006	0.7929
Test		
Normalitas		
Kolmogorov-Smirnov	<0.0100	<0.0100
Kesimpulan	WN/Tidak Normal	WN/ Tidak Normal

Hasil *diagnostic check* pada dua model dugaan produksi cabai rawit menunjukkan bahwa distribusi residual model belum memenuhi asumsi normalitas dikarenakan nilai p-value kurang dari 0,05 walaupun estimasi parameter signifikan dan *White Noise*. Hasil olah ini memberikan dugaan bahwa walaupun data produksi cabai rawit sudah stasioner terhadap mean tetapi diduga belum stasioner terhadap varian. Oleh sebab itu tahapan pemodelan untuk cabai rawit harus diulang kembali dengan mengecek kestasioneran data terhadap varian dan melakukan transformasi data sesuai kebutuhan.




Gambar 10. Box-Cox Plot Data *in sample* Produksi Cabai Rawit

Dari plot data Box-Cox pada Gambar 10 terlihat bahwa nilai *rounded values* dari Lamba sebesar -0,50 yang berarti data belum stasioner terhadap varian dikarenakan tidak bernilai 1 atau interval tidak melalui nilai 1 sehingga diperlukan transformasi data. Transformasi yang digunakan adalah $\hat{Y}_t = (1/\sqrt{Y})$.




Gambar 11. ACF Data *in sample* Transformasi Produksi Cabai Rawit

Pola data ACF menunjukkan data belum stasioner terhadap mean sehingga diperlukan tahapan *differencing*.



Gambar 12. ACF Data *in sample* Transformasi Produksi Cabai Rawit *Differencing* 1



Gambar 13. PACF Data *in sample* Transformasi Produksi Cabai Rawit *Differencing* 1

Berdasarkan plot ACF dan PACF cabai rawit pada Gambar 12 dan 13 maka dugaan awal model ARIMA yang terbentuk yaitu: ARIMA(3,1,0), ARIMA([1,3],1,0) dan ARIMA(0,1,1). Selajutnya dilakukan tahapan estimasi parameter kembali terhadap model dugaan diteruskan dengan tahapan *diagnostic check*.

Tabel 6. Estimasi dan Signifikansi Parameter Model Dugaan pada Data *in sample* Transformasi Produksi Cabai Rawit *Differencing* 1

Parameter	Estimasi/p-values Model Dugaan		
	ARIMA (3,1,0)	ARIMA ([1,3],1,0)	ARIMA (0,1,1)
ϕ_1	-0.40687/ (0.0006)	-0.31581/ (0.0053)	
ϕ_2	-0.27495/ (0.0231)	-0.15266/ (0.1808)	
ϕ_3	-0.24572/ (0.0390)		
θ_1			0.50907/ (<.0001)

Tabel 7. Uji *White Noise* dan Kenormalan Residual Model Dugaan pada Data *in sample* Transformasi Produksi Cabai Rawit *Differencing* 1

Uji White Noise dan Kenormalan Residual Lag	Model Dugaan		
	ARIMA (3,1,0)	ARIMA ([1,3],1,0)	ARIMA (0,1,1)
6	0.3909	0.1254	0.3681
12	0.2797	0.0714	0.1533
18	0.4036	0.1149	0.2374

24	0.5580	0.1988	0.3483
Test			
Normalitas			
Kolmogorov-Smirnov	0.0518	0.0151	>0.1500
Kesimpulan	WN/Normal	WN/Tidak Normal	WN/Normal

Tabel 8. Perbandingan Nilai AIC dan MSE Model ARIMA Produksi Cabai Rawit


Model	<i>In-sample</i>	<i>Out-sample</i>
	AIC	MSE
ARIMA (3,1,0)	-576.161	0.0000237
ARIMA (0,1,1)	-577.763	0.0000248

Dari Tabel 6 terlihat bahwa hanya dua model dugaan yang estimasi semua parameternya signifikan yaitu model ARIMA (3,1,0) dan ARIMA (0,1,1). Demikian pula pada Tabel 7 terlihat hanya dua model dugaan tersebut yang lolos uji *diagnostic check White Noise* dan berdistribusi normal. Adapun model terbaik yang didapatkan berdasarkan nilai AIC dan MSE terkecil adalah model ARIMA(3,1,0).


Berdasarkan model ARIMA terbaik yang didapatkan selanjutnya digunakan untuk meramalan data produksi cabai besar dan cabai rawit pada tahun 2019.

Tabel 9. Nilai Ramalan Produksi Cabai Besar dan Cabai Rawit Tahun 2019

Bulan	Nilai Ramalan Produksi	
	Cabai Besar	Cabai Rawit
Januari	102,4854	312,1527
Februari	90,6092	299,3259
Maret	103,9670	296,2428
April	103,9175	299,3259
Mei	102,6962	302,4575
Juni	99,1667	300,3643
Juli	101,5100	299,3259
Agustus	101,9657	300,3643
September	101,9593	300,3643
Oktober	101,0568	300,3643
Nopember	101,3949	300,3643
Desember	101,5539	300,3643



Gambar 14. Produksi dan Nilai Ramalan Cabai Besar, Jan 2012-Des 2019 (ton)



Gambar 15. Produksi dan Nilai Ramalan Cabai Rawit, Jan 2012-Des 2019 (ton)

KESIMPULAN

Model ARIMA terbaik yang dapat diterapkan berdasarkan kriteria AIC dan MSE terkecil terhadap data jumlah produksi cabai besar dan cabai rawit di Provinsi Kalimantan Tengah adalah ARIMA(3,1,0). Pada proses pemodelan cabai besar diperlukan proses *differencing* untuk menstasionerkan data terhadap mean sedangkan pada data cabai rawit diperlukan transformasi data dan *differencing* untuk menstasionerkan data terhadap varian dan mean.

DAFTAR PUSTAKA

Abinowi, Egi. 2018. Peramalan Curah Hujan, Produksi dan Kebutuhan Cabai Menggunakan Metode ARIMA dan *Intervention Model*. Universitas Komputer Indonesia.

Box, G. E. P., Jenkins, G. M. 1970. *Time Series Analysis, Forecasting, and Control*. Oakland, CA: Holden-Day.

Badan Pusat Statistik. 2013-2019. Statistik Tanaman Sayuran dan Buah-buahan Semusim

Indonesia.

Hadiansyah, F. N. 2017. Prediksi Harga Cabai dengan Modelan Time Series ARIMA. Indonesian Journal and Computing, Vol. 2, Issue. 1, Maret 2017, PP. 71-78.

Karima, Dewi. 2018. Kajian Peramalan Produksi Cabai Besar dengan Pendekatan *Seasonal* ARIMA. Institut Pertanian Bogor.

Nabilah. 2017. Peramalan Harga dan Produksi Cabai Rawit di Provinsi Jawa Timur. Institut Teknologi Sepuluh Nopember.

Perihatini, D. I., Lestari, I. F., Primandari, A. H. 2018. Peramalan Harga Cabai Merah Besar Keriting Kabupaten Banyumas Menggunakan Metode ARIMA Box-Jenkins. Prosiding KNPMP III 2018, ISSN: 2502-6526.

Suhartono. 2009. *Analisis Data Statistik dengan R*. Graha Ilmu.

Lampiran Hasil Olah SAS

Autocorrelation Check for white Noise

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	18.51	6	0.0051	-0.352	-0.002	-0.226	0.215	-0.063	-0.050	
12	24.48	12	0.0175	0.189	-0.152	-0.035	-0.030	0.075	0.036	
18	25.13	18	0.1213	-0.030	0.035	-0.045	-0.038	0.009	0.031	

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	-0.46493	0.11069	-4.20	<.0001	1
AR1,2	-0.28514	0.11825	-2.41	0.0184	2
AR1,3	-0.34287	0.11143	-3.08	0.0029	3

Variance Estimate 204.4196
Std Error Estimate 14.29754
AIC 631.11
SBC 638.1414
Number of Residuals 77
* AIC and SBC do not include log determinant.

Autocorrelation Check for white Noise

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	11.17	6	0.0832	-0.298	-0.084	-0.111	0.076	0.110	-0.107	
12	20.46	12	0.0588	-0.141	0.013	0.070	0.199	-0.193	0.026	
18	25.53	18	0.1111	0.102	-0.049	0.013	-0.122	-0.020	0.150	

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	-0.40687	0.11385	-3.57	0.0006	1
AR1,2	-0.27495	0.11855	-2.32	0.0231	2
AR1,3	-0.24572	0.11695	-2.10	0.0390	3

Variance Estimate 0.000032
Std Error Estimate 0.005632
AIC -376.161
SBC -369.129
Number of Residuals 77
* AIC and SBC do not include log determinant.