



PERAMALAN PRODUKSI BANGGAI CARDINALFISH MENGGUNAKAN METODE *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (ARIMA)

Oleh: Indah Manfaati Nur¹, Rara Ayu Puspita²
Universitas Muhammadiyah Semarang
Email : indahmnur@unimus.ac.id

Article history	Abstract
Keywords: Kata kunci: ARIMA, Banggai <i>Cardinalfish</i> , Peramalan	The ARIMA (Autoregressive Integrated Moving Average) method is a very appropriate method to use for the short term because the ARIMA method has very accurate accuracy. And also determine a good relationship between the variables to be forecasted with the value used for forecasting. This study uses the ARIMA method. The purpose of the study was to predict the production of Banggai Cardinalfish (<i>Pterapogon kauderni</i>) which is an ornamental fish commodity that is in great demand. High market demand and production predictions are able to provide the market, becoming important information so that potentials and opportunities can be exploited. The accuracy of the resulting forecast is calculated using the MSE (Mean Squared Error) and MAE (Mean Absolute Error) values. Forecasting results from Banggai Cardinalfish production using the ARIMA method were 830.33 in May 2017 with the resulting MAPE value of 176.93 and MAE of 975.23.

Pendahuluan

Banggai *Cardinalfish*

Banggai *cardinalfish* (*Pterapogon kauderni*) salah satu komoditas perikanan ikan hias yang banyak diminati masyarakat saat ini. Permintaan pasar baik dari dalam maupun luar negeri ikan hias tersebut, cenderung meningkat, menjadikannya potensi dan peluang untuk bisa dimanfaatkan. Saat ini pasokan utama kebutuhan pasar, sebagian besar didapat dari

hasil penangkapan di alam (Ndobe, 2013), menjadikan usaha budidaya menjadikannya sangat mendesak untuk menggeser pasokan dari alam.

Kebutuhan pasar yang tinggi dan dapat memprediksi kemampuan produksi benih dalam menyuplai kebutuhan pasar, menjadi informasi yang sangat penting. Salah satu hal yang diperlukan dalam perencanaan produksi benih Banggai *Cardinalfish* adalah bagaimana membuat prediksi kemampuan produksi benih ikan banggai yang dibudidayakan. Hasil prediksi

kemampuan produksi benih yang dihasilkan, selanjutnya dapat dijadikan dasar dalam menentukan kebijakan yang akan diambil untuk menjawab tantangan dan peluang pasar.

Autoregressive Integrated Moving Average (ARIMA)

Metode *Autoregressive Integrated Moving Average* (ARIMA) yang biasa disebut dengan metode Box-Jenkins merupakan metode yang dikembangkan oleh George Box dan Gwilym Jenkins pada tahun 1970 [1]. Metode ARIMA (*Autoregressive Integrated Moving Average*) adalah metode yang digunakan untuk peramalan jangka pendek. Penggunaan metode ARIMA dalam peramalan jangka pendek sangat tepat digunakan karena metode ARIMA memiliki ketepatan yang sangat akurat. Dan juga menentukan hubungan statistik yang baik antar variabel yang akan diramal dengan nilai yang digunakan untuk peramalan. Sedangkan untuk peramalan jangka panjang ketepatan peramalannya kurang baik. Biasanya nilai peramalan akan cenderung konstan untuk periode yang cukup panjang.

Model *Autoregressive Integrated Moving Average* (ARIMA) adalah model yang secara penuh mengabaikan variabel independen dalam membuat peramalan. Nilai yang digunakan oleh ARIMA untuk peramalan yaitu menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan peramalan jangka pendek yang akurat [2]. Kelompok model yang termasuk dalam metode *Autoregressive Integrated Moving Average* (ARIMA) yaitu:

1. *Autoregressive* (AR)

Model *Autoregressive* (AR) diperkenalkan pertama kali oleh Yule pada tahun 1926 dan kemudian dikembangkan oleh Walker pada tahun 1931. Asumsi yang dimiliki oleh model ini adalah data periode sekarang dipengaruhi oleh data pada periode sebelumnya. Disebut model *Autoregressive* dikarenakan pada model ini diregresikan terhadap nilai-nilai sebelumnya dari variabel itu sendiri. Model *Autoregressive* dengan

ordo p disingkat menjadi AR(p) atau ARIMA($p,0,0$) [5] Model :

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} - a_t \quad (1)$$

dimana :

- Z_t = deret waktu stasioner
- μ = konstanta
- Z_{t-p} = variabel bebas
- ϕ_p = koefisien parameter *autoregressive*
- ke- p
- a_t = sisaan pada saat ke- t

Model diatas disebut sebagai model *Autoregressive* (regresi diri sendiri) karena model tersebut mirip dengan persamaan regresi pada umumnya, hanya saja yang menjadi variabel independen bukan variabel yang berbeda dengan variabel dependen melainkan nilai sebelumnya (lag) dari variabel dependen (Z_t) itu sendiri.

2. *Moving Average* (MA)

Model *Moving Average* (MA) pertama kali diperkenalkan oleh Slutsky pada tahun 1973, dengan orde q ditulis MA (q) atau ARIMA ($0,0,q$) dan dikembangkan oleh Wadsworth pada tahun 1989 [3]. Model :

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2)$$

Dimana :

- Z_t = deret waktu stasioner
- μ = konstanta
- a_{t-1} = variabel bebas
- θ_q = koefisien parameter *moving average*
- ke- q
- a_t = sisaan pada saat ke- t

3. *Autoregressive Moving Average* (ARMA)

Model *Autoregressive Moving Average* (ARMA) merupakan model gabungan dari *Autoregressive* (AR) dan *Moving Average* (MA). Dan model ini memiliki asumsi bahwa data periode sekarang dipengaruhi oleh data periode sebelumnya dan nilai sisaan dari periode sebelumnya [4]. Model :

$$Z_t = \mu + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (3)$$

Dimana:

- Z_t = deret waktu stasioner
- μ = konstanta
- Z_{t-p} = variabel bebas

- ϕ_p = koefisien
- a_{t-1} = variabel bebas
- θ_q = koefisien parameter *moving average*
- ke-q
- a_t = sisaan pada saat ke-t

4. *Autoregressive Integrated Moving Average (ARIMA)*

Model *Autoregressive Integrated Moving Average (ARIMA)* digunakan berdasarkan asumsi bahwa data deret waktu yang digunakan harus stasioner yang artinya rata-rata variasi dari data yang dimaksud adalah konstan. Namun, ada beberapa hal yang terjadi ketika suatu data tidak stasioner. Dalam mengatasi ketidakstasioneran data ini dilakukan proses differencing agar data menjadi stasioner. Karena model *Autoregressive (AR)*, *Moving Average (MA)*, *Autoregressive Moving Average (ARMA)* tidak mampu menjelaskan arti dari differencing, maka digunakan model campuran yang disebut *Autoregressive Integrated Moving Average (ARIMA)* atau *ARIMA (p,d,q)* sehingga menjadi lebih efektif dalam menjelaskan proses differencing. Pada model campuran ini series stasioner merupakan fungsi linier dari nilai lampau beserta nilai sekarang dan kesalahan lampainya. Model :

$$\Phi_p(B) D^d Z_t = \mu + \theta_q(B) a_t \quad (4)$$

Dimana :

- Φ_p = koefisien parameter autoregressive ke-
- θ_q = koefisien parameter moving average ke-q
- B = operator backshift
- D = differencing
- μ = konstanta a_t = sisaan pada saat ke-t
- p = derajat *autoregressive*
- d = tingkat proses differencing
- q = derajat moving average parameter *autoregressive* ke-p

Metode Penelitian

Data yang digunakan adalah data sekunder yaitu produksi Banggai Cardinalfish dari Balai Perikanan Budidaya Laut Ambon tahun 2013-2016

Tahapan ARIMA

Analisa data dilakukan dengan menggunakan metode ARIMA. Tahapan penerapan model ARIMA secara berturut – turut adalah sebagai berikut:

1. Menampilkan plot data
Plot data digunakan untuk mengetahui pola data, apakah data berpola stasioner, trend, musiman maupun siklus.
2. Identifikasi model stasioner atau tidak stasioner
Stasioneritas berarti tidak terdapat pertumbuhan atau penurunan pada data. Data secara umum harus horizontal sepanjang sumbu waktu. Kestasioneran data digunakan untuk mengetahui kelayakan data untuk dianalisa menggunakan metode deret waktu. Jika data tidak stasioner maka perlu dilakukan differencing (pembeda) untuk data yang tidak stasioner terhadap rata-rata atau transformasi jika data tidak stasioner pada varian. Identifikasi model sementara dilakukan untuk menentukan model analisis deret waktu berdasarkan *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)*.
3. Estimasi parameter
Untuk model sementara yang terpilih, parameter-parameternya diestimasi dengan melakukan uji hipotesis untuk mengetahui apakah parameter signifikan atau tidak. Hasil estimasi yang diperoleh akan digunakan untuk menentukan model akhir dalam melakukan peramalan.
Hipotesis :
 H_0 : parameter tidak signifikan
 H_1 : parameter signifikan
Level toleransi (α) : 5% = 0,05
Kriteria uji : Tolak H_0 jika p-value < α
4. Verifikasi model
Verifikasi model dapat dilakukan dengan dua cara yaitu overfitting dan

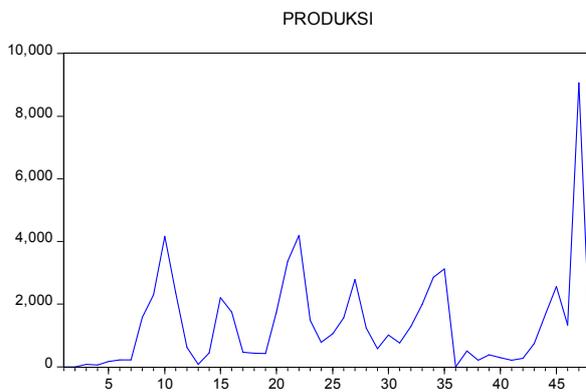
uji residual. Overfitting dilakukan apabila diperlukan model yang lebih luas. Sedangkan uji residual digunakan untuk melihat kelayakan model dengan mengamati residual data melalui plot ACF dan PACF. Jika hasil verifikasi menentukan model tidak sesuai, maka model harus diubah sampai diperoleh model yang sesuai digunakan.

5. Pemilihan Model Terbaik
6. Peramalan
Setelah model terpilih maka peramalan dapat dilakukan untuk lima periode ke depan.

Hasil Penelitian dan Pembahasan

1. Analisis Deskriptif

Analisis deskriptif dilakukan terlebih dahulu sebelum dilakukan pengujian lebih lanjut hal ini untuk mengetahui ukuran pemusatan, ukuran penyebaran, dan melihat secara visual data dalam bentuk plot. Pada data produksi Binggai tahun 2013 hingga tahun 2016 memiliki hasil produksi terendah sebesar 0 sedangkan produksi tertinggi sebesar 9067 dan memiliki rata-rata produksi sebesar 1357,33 dengan standar deviasi 1593,99. Berikut plot data untuk produksi kedelai :

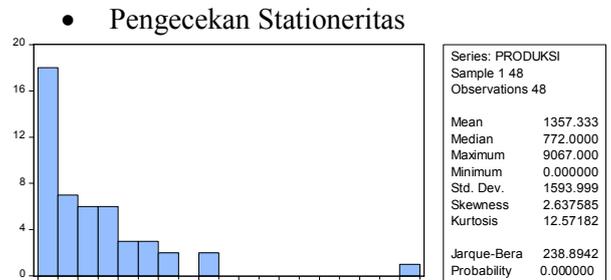


Gambar 1.1. Plot Deret Waktu Produksi Binggai Tahun 2013-2016

Gambar 1.1 merupakan plot deret waktu pada data produksi Binggai tahun 2013 hingga tahun 2016. Plot data merupakan tahap awal pada pemodelan deret waktu, karena dari plot data ini dapat diketahui *trend* data dan

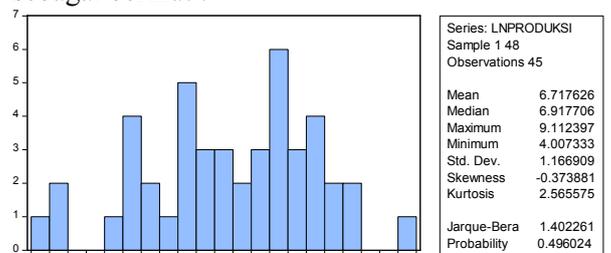
rata-rata Bergeraknya suatu data deret waktu. Pada plot data produksi Binggai menunjukkan bahwa hasil produksi Binggai cenderung mempunyai *trend* naik dan sangat fluktuatif. Bahkan sebelum pada bulan November 2016 produksi Binggai cukup tinggi dan sebulan kemudian mengalami penurunan.

ARIMA



Gambar 1.2. Histogram Produksi Binggai Tahun 2013-2016

Dilihat dari gambar 1.2 diatas, dapat dilihat nilai Probability < alpha = 0.0000 < 0.05 yang dapat diartikan bahwa data produksi binggai belum mengikuti sebaran normal dan diduga data belum stasioner terhadap varians, artinya data produksi binggai tidak memiliki flutuasi yang stabil atau tidak sama dari waktu ke waktu. Karena data belum stasioner terhadap waktu maka dilakukan transformasi. Hasil transformasi data yang didapatkan sebagai berikut :



Gambar 1.3. Histogram Produksi Binggai Tahun 2013-2016 setelah ditransformasi

Dilihat dari gambar 1.3 diatas, dapat dilihat nilai Probability > alpha = 0.4960 > 0.05 yang dapat diartikan bahwa data produksi binggai sudah mengikuti sebaran normal dan data telah stasioner terhadap varians, artinya data produksi binggai memiliki flutuasi yang stabil atau hampir sama dari waktu ke waktu.

Selanjutnya adalah melihat kestasioneran data terhadap mean.

Pengujian untuk melihat kestasioneran data runtun waktu (*time series*) bisa menggunakan uji *Augmented Dickey Fuller* (ADF). Uji ADF merupakan pengujian stasioner dengan menentukan apakah data runtun waktu mengandung akar unit (*Unit Root*). Hipotesis yang digunakan dalam uji ADF adalah sebagai berikut :

- $H_0 : \delta = 1$ (tidak stasioner)
- $H_1 : \delta < 1$ (stasioner)
- H_0 diterima jika nilai *P-Value* > 5%
- Hasil uji ADF dijelaskan pada Tabel 1.1. berikut :

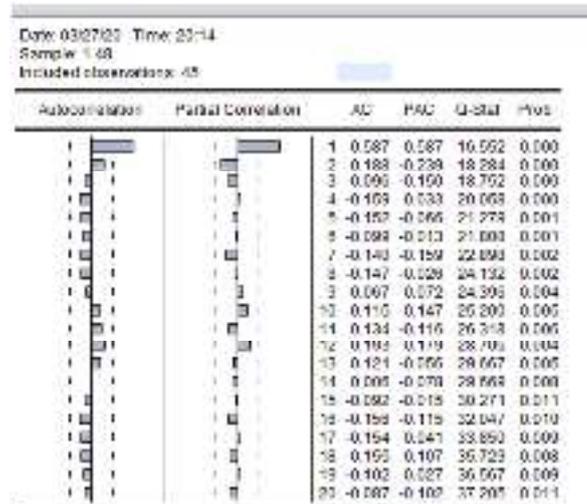
Tabel 1.1. Uji ADF

Null Hypothesis: LNPRODUKSI has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic - based on SIC, maxlag=9)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.349871	0.0186
Test critical values:		
1% level	-3.592462	
5% level	-2.931404	
10% level	-2.603944	

*MacKinnon (1996) one-sided p-values.

Berdasarkan Tabel 1.1. diatas bahwa data produksi Banggai sudah stasioner terhadap mean. Hal ini dibuktikan dengan nilai p-value dari Prob. ADF Statistik < alpha = 0.018 < 0.05 yang artinya H_0 ditolak. Sehingga dapat disimpulkan data produksi Binggai tidak mengandung *unit root* atau dalam arti lain data sudah stasioner.



Gambar 1.4. Plot Kolerogram

Dari plot autokorelasi(ACF) terlihat bahwa plot yang terbentuk memiliki pola Diss Down dan plot autokorelasi parsial(PACF) terlihat bahwa mengalami *cutoff*(turun drastis) pada baris pertama tetapi pada lag selanjutnya seperti mengalami pola Diss Down. Ada beberapa kemungkinan model yang didapatkan jika di lihat dari plot ACF dan plot PACF nya, kemungkinan model yang didapatkan adalah ARIMA(1,0,0) dengan nila p=1 dan q=0, ARIMA(0,0,1) dengan p=0 dan q=1, ARIMA(1,0,1) dengan p=1 dan q=1, ARIMA(2,0,1) dengan p=2 dan q=1, ARIMA(1,0,2) dengan p=1 dan q=2.

• **Estimasi Parameter**

Dari beberapa kemungkinan model yang didapatkan, diuji parameteranya dan diperoleh hasil sebagai berikut :

Tabel 1.2. Estimasi Parameter Model ARIMA

Model	Estimasi Parameter		
	Type	P-Value	Keterangan
ARIMA(1,0,0) c	AR(1)	0.0000	Signifikan
ARIMA(0,0,1) c	MA(1)	0.0002	Signifikan
ARIMA(1,0,1) c	AR(1)	0.0678	Tidak Signifikan
	MA(1)	0.2970	Tidak Signifikan
ARIMA(2,0,1) c	AR(1)	0.0001	Signifikan
	AR(2)	0.0882	Tidak Signifikan
	MA(1)	0.0000	Signifikan
ARIMA(1,0,2) c	AR(1)	0.0000	Signifikan
	MA(1)	0.0001	Signifikan
	MA(2)	0.6664	Tidak

Model	Estimasi Parameter			Bulan	Hasil Peramalan
	Type	P-Value	Keterangan	Januari 2017	986,23
			Signifikan	Februari 2017	830,33
				Maret 2017	830,33
				April 2017	830,33
				Mei 2017	830,33

Berdasarkan tabel 1.2. diatas, menunjukkan bahwa p-value yang signifikan menggunakan ARIMA(1,0,0)c dan juga ARIMA(0,0,1)c. Hal ini dapat dilihat pada p-value yang diperoleh adalah p-value < 0.05. karena ada dua model yang signifikan, maka dilihat nilai AIC, SC dan beberapa Asumsi dari ARIMA yaitu Normalitas, Autokorelasi dan Heteroskedastisitas untuk mengetahui model mana yang terbaik.

- Pemilihan Model Terbaik

Tabel 1.3. Pemilihan Model Terbaik

Model	AIC	SC
ARIMA (1,0,0) c	2.7908	2.9113
ARIMA (0,0,1) c	2.8440	2.9644

Model	Normalitas	Auto korelasi	Heteroskedastisitas
ARIMA (1,0,0) c	Normal	Tidak Terjadi	Tidak Terjadi
ARIMA (0,0,1) c	Normal	Tidak Terjadi	Tidak Terjadi

Menurut tabel 1.3. diatas, dari dua model ARIMA yang signifikan yaitu ARIMA(1,0,0)c dan ARIMA(0,0,1)c dilihat nilai AIC, SC, dan asumsinya untuk mendapatkan model terbaik. Model ARIMA(1,0,0)c memiliki nilai AIC sebesar 2,790830 dan SC sebesar 2,911274 dan semua asumsinya terpenuhi, sementara model ARIMA(0,0,1)c memiliki nilai AIC sebesar 2,843979 dan nilai SC sebesar 2,964423 dan semua asumsinya terpenuhi. Model ARIMA(1,0,0)c memiliki nilai AIC dan SC yang lebih kecil dibandingkan dengan model ARIMA(0,0,1)c sehingga didapatkan model terbaik yaitu model ARIMA(1,0,0)c. Tahap selanjutnya adalah peramalan, didapatkan hasil peramalan dari model ARIMA(1,0,0)c adalah sebagai berikut :

Tabel 1.4. Hasil Peramalan Model ARIMA(1,0,0)c

2. Evaluasi Hasil Peramalan

Tabel 1.5. Evaluasi Hasil Peramalan

Evaluasi Hasil Peramalan	Metode ARIMA(1,0,0)c
RMSE	1480,613
MAE	975,23
MAPE	176,93

Dari tabel 1.5. diatas diketahui bahwa nilai evaluasi *error* pada ARIMA(1,0,0)c. Hal ini dilihat dari nilai MAE dan MAPE yang kecil. Pada tahap perhitungan evaluasi dari hasil Peramalan, dengan menggunakan dasar tersebut analisis perbandingan metode dilakukan. Dari penelitian yang dilakukan, pada data Binggai metode ARIMA jauh lebih baik karena memiliki MAPE dan MAE yang kecil, namun jika dilihat dengan RMSE metode ARIMA memiliki nilai yang lebih besar dibandingkan metode lain. Perbandingan evaluasi error setiap metode dilakukan dengan cara melihat RMSE, MAPE dan MAE setiap metode. Evaluasi error metode ARIMA memiliki RMSE 1480,61, MAPE 176,93 dan MAE 975,23. Dari evaluasi error dapat disimpulkan bahwa metode ARIMA memiliki evaluasi error yang kecil untuk data produksi Binggai.

Simpulan dan Saran

Simpulan

Dari penelitian yang dilakukan, pada data Binggai metode ARIMA jauh lebih baik karena memiliki MAPE dan MAE yang kecil, namun jika dilihat dengan RMSE metode ARIMA memiliki nilai yang lebih besar dibandingkan metode lain. Perbandingan evaluasi error setiap metode dilakukan dengan cara melihat RMSE, MAPE dan MAE setiap metode. Evaluasi error metode ARIMA memiliki RMSE 1480,61, MAPE 176,93 dan MAE 975,23. Dari perbandingan evaluasi error dapat disimpulkan bahwa metode ARIMA memiliki evaluasi error yang kecil untuk data produksi Binggai.

Daftar Pustaka

- [1] Iriawan, N dan P.S. Astuti, “Mengolah Data Statistik Dengan Mudah Menggunakan Minitab 14”, Penerbit Andi, Yogyakarta, 2006.
- [2] Samliok Ndobe, Abigail Moore, Al Ismi M. Salanggon, Muslihudin, dkk., (2013) Pengelolaan Banggai *Cardinalfish* (Pterapogon Kauderni) Melalui Konsep Ecosystem-Based Approach (Banggai *Cardinalfish* (Pterapogon Kauderni) Managementan Ecosystem-Based Approach. Marine Fisheries Journal.
- [3] Samliok Ndobe, Irawaty Widiastuti, Abigail Moore., (2013). Sex Ratio dan Pemangsaan Rekrut pada Ikan Hias Banggai *Cardinalfish* (Pterapogon kauderni). Konferensi Akuakultur Indonesia,
- [5] Razak. Abd. Fadhilah, “Load Forecasting Using Time Series Models”. Jurnal Kejuruteraan, 2009, 21: 53-62.
- [6] Halim, “Diktat Time Series”, Universitas Kristen Petra, Surabaya, 2006.
- [7] Assauri, S, “Teknik dan Metode Peramalan. Penerapannya Dalam Ekonomi dan Dunia Usaha Edisi Satu”, LP Fakultas Ekonomi UI, Jakarta, 1984.
- [8] Zhang, G., Eddy Patuwo, B. and Y Hu M. (1998). “Forecasting with artificial neural networks: The state of the art.” International Journal of Forecasting, Vol. 14, No. 1, pp. 35-62, DOI: 10.1016/S01692070(97)00044-7.
- [9] Thoplan, R. (2014). “Simple v/s sophisticated methods of forecasting for mauritius monthly tourist arrival data.” International Journal of Statistics and Applications, Vol. 4, No. 5, pp. 217-223, DOI: 10.5923/j.statistics.20140405.01.
- [10] Maleki, A., Simin Nasserli., Mehri S.A., dan Mahdi Hadi. (2018). “Comparison of ARIMA and NNAR Models for Forecasting Water Treatment Plant's Influent Characteristics”. KSCE Journal of Civil Engineering (0000) 00(0):1-13, DOI 10.1007/s12205-018-1195-z.