



PENERAPAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) UNTUK PREDIKSI BILANGAN SUNSPOT

Application of Autoregressive Integrated Moving Average (ARIMA) Method for Sunspot Number Prediction

Felia Dria Yuliawanti¹, Dian Candra Rini Novitasari^{2*}, Nanang Widodo³,
Abdulloh Hamid⁴, Wika Dianita Utami⁵

^{1,2,4,5} Matematika, Fakultas Sains dan Teknologi, UIN Sunan Ampel Surabaya,

³Balai Pengamatan Antariksa dan Atmosfer Pasuruan

^{1,2,4,5}Jl. Ahmad Yani No.117, Surabaya, 60237, Indonesia

³Jl. Raya Gempol - Mojokerto Km.03, Pasuruan, 67155, Indonesia

Corresponding author e-mail: ^{2*} diancrini@uinsby.ac.id

Abstrak

Peristiwa magnetik pada matahari ditandai dengan salah satu tanda yaitu munculnya *sunspot* atau bintik matahari. *Sunspot* terletak di fotosfer matahari yang memiliki warna lebih gelap dari pancaran sekitarnya. Tujuan dari penelitian ini adalah untuk memprediksi bilangan *sunspot* dengan menggunakan metode ARIMA. Metode ARIMA dilakukan dengan melihat plot ACF dan PACF untuk mendapatkan model yang akan digunakan dalam prediksi. Penelitian ini menggunakan data bilangan *sunspot* yang dimulai dari bulan Januari tahun 1987 hingga bulan Desember 2019 sebanyak 396 data. Dari data tersebut didapatkan 4 model ARIMA yaitu ARIMA(3,1,2), ARIMA(3,1,1), ARIMA(2,1,2), ARIMA(2,1,1). Dari keempat model tersebut, model terbaik yang digunakan untuk prediksi yaitu ARIMA(2,1,2) dengan nilai AIC sebesar -884,87.

Kata Kunci : Prediksi, Sunspot, Autoregressive Integrated Moving Average, ARIMA

Abstract

One of the magnetic events in the sun is the appearance of sunspots. The sunspot is located in the sun's photosphere and has a darker colour than the surrounding radiance. The purpose of this research was to predict sunspot numbers using the ARIMA method. The ARIMA method is done by looking at the ACF and PACF plots to get a model that will be used in the predictions. The data used in this research is sunspot number data that started from January 1987 to December 2019 as many as 396 data. From the data obtained 4 models of ARIMA namely ARIMA(3,1,2), ARIMA(3,1,1), ARIMA(2,1,2), ARIMA(2,1,1). Of the four models, the best prediction model is ARIMA(2,1,2) by an AIC value of -884,87.

Keywords: Prediction, Sunspot, Autoregressive Integrated Moving Average, ARIMA

Article info:

Submitted: 15th April 2021

Accepted: 29th July 2021

How to cite this article:

F. D. Yuliawanti, D. C. R. Novitasari, N. Widodo, A. Hamid, and W. D. Utami, "PENERAPAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) UNTUK PREDIKSI BILANGAN SUNSPOT", BAREKENG: J. Il. Mat. & Ter., vol. 15, no. 03, pp. 555-564, Sep. 2021.



This work is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](#).

Copyright © 2021 Felia Dria Yuliawanti, Dian Candra Rini Novitasari, Nanang Widodo, Abdulloh Hamid, Wika Dianita Utami



1. PENDAHULUAN

Matahari merupakan sumber yang sangat penting bagi kehidupan manusia, karena memiliki sumber energi yang tak terbatas. Pada fotosfer matahari terdapat fenomena *sunspot* [1]. *Sunspot* merupakan perpotongan tabung medan magnet matahari dengan fotosfer yang terjadi karena aktivitas medan magnet yang sangat kuat pada permukaan matahari yang dipengaruhi oleh rotasi diferensial matahari [2], [3]. *Sunspot* memiliki warna gelap dibandingkan sekitarnya di permukaan matahari dikarenakan suhu yang dimiliki lebih rendah daripada suhu fotosfer yaitu sekitar 4000°K sampai 4500°K [4], [5]. Munculnya *sunspot* menunjukkan adanya daerah aktif di matahari, jika daerah aktif semakin luas kemunculannya berpotensi besar menyebabkan terjadinya *flare* (ledakan matahari) [6]. *Sunspot* juga memiliki dampak buruk pada iklim dan cuaca di bumi sehingga dapat mengganggu aktivitas manusia [7]. *Sunspot* memiliki periode rata-rata satu siklus matahari sekitar 11 tahun, sedangkan untuk periode siklus polaritas *sunspot* adalah sekitar 22 tahun yang dicatat berdasarkan *time series* (runtun waktu). Data *time series* dapat digunakan untuk memprediksi data di masa mendatang. Oleh karena itu, prediksi baik digunakan untuk mengantisipasi dampak buruk yang ditimbulkan oleh *sunspot*. Banyak metode yang dapat digunakan untuk prediksi dengan data *time series* salah satunya adalah metode ARIMA [4], [8].

Metode ARIMA merupakan salah satu metode *time series* yang ditemukan pada tahun 1970 oleh George Box dan Gwilym Jenkins sehingga metode ini juga dapat disebut dengan *Box-Jenkins* [9], [10]. Metode ARIMA sangat efisien untuk digunakan sebagai prediksi jangka pendek secara cepat karena hanya memanfaatkan data variabel yang hendak diramalkan saja dan memiliki akurasi yang baik [11].

Terdapat beberapa penelitian terdahulu yang menggunakan metode ARIMA untuk melakukan prediksi, antara lain penelitian tentang prediksi harga *bitcoin* didapatkan model ARIMA(0,2,1) dengan nilai MAPE yang baik yaitu sebesar 4,753% [12]. Selain itu pada penelitian lain tentang prediksi harga gula pasir di Jakarta yang membandingkan metode ARIMA dengan MA diperoleh model terbaiknya adalah ARIMA(2,1,1), sedangkan untuk metode MA kurang sesuai karena hasil peramalan untuk 30 hari ke depan menunjukkan hasil yang sama [13]. Metode ARIMA juga baik digunakan untuk meramal pergerakan inflasi daripada metode AR dan MA, dengan nilai *Sum Square Error* ARIMA, AR dan MA masing-masing sebesar 23,22; 31,51 dan 577,36 [11]. Sementara, pada penelitian tentang bilangan *sunspot* didapatkan model AR(1) atau ARIMA(1,0,0) dengan nilai koefisiensi korelasi sebesar 96,5% [10]. Lalu pada penelitian estimasi tren dan perkiraan univariat dari bilangan *sunspot* dikatakan bahwa model ARMA(11,1) dan ARIMA(8,1,1) baik digunakan untuk meramalkan rata-rata bilangan *sunspot* tahunan [14].

Berdasarkan referensi dan beberapa penelitian mengenai *sunspot* dan metode ARIMA di atas, akan dilakukan penelitian tentang memprediksi bilangan *sunspot* bulanan dengan menggunakan metode ARIMA. Penelitian ini diharapkan dapat memprediksi *sunspot* untuk mengantisipasi efek buruk yang ditimbulkan bagi keadaan antariksa dan bumi sehingga tidak mengganggu aktivitas manusia.

2. METODE PENELITIAN

Pada ARIMA, terdapat beberapa metode yang berkaitan yaitu *Autoregressive, Moving Average, Autoregressive Moving Average* dan *Autoregressive Integrated Moving Average* (ARIMA). *Autoregressive* merupakan sebuah metode dimana data pada periode sebelumnya sangat berdampak atau berpengaruh terhadap data saat ini [10], [12].

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

Keterangan

Z_t : deret waktu

ϕ_p : parameter *autoregressive*

e_t : nilai *error*

Moving Average merupakan model yang pertama kali dikenalkan pada tahun 1973 oleh Slutsky dan kemudian pada tahun 1989 dikembangkan oleh Wadsworth [10], [12].

$$Z_t = e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2)$$

Keterangan

Z_t : deret waktu

θ_q : parameter *moving average*

e_t : nilai *error*

Autoregressive Moving Average merupakan model yang mengkombinasikan antara *Autoregressive* dan *Moving Average* dengan bentuk umum sebagai berikut [10], [12].

$$Z_t = \phi_1 Z_{t-1} + \cdots + \phi_p Z_{t-p} + e_t - \theta_1 e_{t-1} - \cdots - \theta_q e_{t-q} \quad (3)$$

Keterangan

Z_t : deret waktu

ϕ_p : parameter *autoregressive*

e_t : nilai *error*

θ_q : parameter *moving average*

ARIMA merupakan model dengan dugaan data yang digunakan harus stasioner dengan *mean* dan varians, sehingga dibutuhkan proses *differencing* (pembedaan) yang tidak sanggup dijelaskan oleh model AR, MA dan ARMA [12].

$$\phi_p(B)D^d Z_t = \mu + \theta_q(B)e_t \quad (4)$$

Keterangan

ϕ_p : parameter *autoregressive*

θ_q : parameter *moving average*

B : operator *backshift*

D : *differencing*

μ : konstanta

e_t : nilai *error*

p : derajat *autoregressive*

q : derajat *moving average*

d : tingkat *differencing*

Penelitian ini menggunakan data bilangan *sunspot* setiap bulan yang diperoleh dari <https://www.sidc.be/silso/> [7]. Data yang digunakan sebanyak 396 data yang dimulai dari bulan Januari tahun 1987 hingga bulan Desember 2019 dengan variabel terikat (Y) yaitu bilangan *sunspot* dan variabel bebas (X) yaitu periode waktu yang ditunjukkan pada Tabel 1, sebagai berikut:

Tabel 1. Data bilangan *sunspot*

Tahun	Bulan	Bilangan <i>sunspot</i>
1987	1	9,8
1987	2	3,4
1987	3	17,4
:	:	:
2019	11	0,5
2019	12	1,5

Sumber data: [7]

Dalam menyelesaikan permasalahan pada penelitian ini, dilakukan beberapa tahapan metode ARIMA sebagai berikut:

1. Pengumpulan data bilangan *sunspot* dari tahun 1987 hingga 2019 serta menentukan variabel terikat (Y) dan variabel bebas (X).
2. Normalisasi data

Salah satu metode untuk normalisasi adalah *min-max*. Normalisasi *min-max* merupakan metode yang menskala ulang data dari rentang yang lama ke rentang yang baru dengan rentang yang digunakan antara 0 dan 1 [15], [16].

$$x' = \frac{x - \min\{x_k\}}{\max\{x_k\} - \min\{x_k\}} \quad (5)$$

Keterangan

x' : nilai normalisasi

x : nilai data

$\min\{x_k\}$: nilai minimal dari suatu data

$\max\{x_k\}$: nilai maksimal dari suatu data

3. Identifikasi

Identifikasi dilakukan melalui plot dari data *time series*, sehingga diketahui kestasioneran sebuah data [17]. Data yang digunakan harus stasioner terhadap *mean* dan varians [18]. Jika data *time series* tidak stasioner, maka diperlukan proses *differencing* untuk menstasionerkan data terhadap *mean* dan ini sudah menjadi bagian dari pemodelan ARIMA [19], [20].

$$Z'_t = Z_t - Z_{t-1} \quad (6)$$

Keterangan

Z'_t : nilai data yang di-*differencing*

Z_t : nilai data aktual

Sedangkan untuk transformasi digunakan pada data yang tidak stasioner terhadap varians dengan transformasi *Box-Cox* [19].

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (7)$$

Keterangan

$T(Z_t)$: nilai data yang ditransformasi

Z_t : nilai data aktual

λ : diperoleh dari metode maksimum *likelihood*

Jika data telah stasioner, maka bisa didapatkan model ARIMA(p, d, q) dengan d merupakan tingkat *differencing* data, orde p dan orde q merupakan lag yang keluar dari garis signifikan atau garis putus-putus pada plot PACF (*Partial Autocorrelation Function*) dan plot ACF (*Autocorrelation Function*) [17].

4. Estimasi Parameter

Dari beberapa model yang sudah diperoleh, kemudian dilakukan uji hipotesis agar dapat mengetahui signifikansi suatu parameter dengan hipotesis awal H_0 : parameter tidak signifikan dan H_1 : parameter signifikan. Untuk kriteria uji yang digunakan yaitu H_0 ditolak jika $p\text{-value} < \alpha$ ($5\% = 0,05$) [12], [18].

Jika terdapat lebih dari satu model ARIMA(p, d, q) yang memenuhi hipotesis H_1 , maka dapat dipilih satu model terbaik dengan nilai AIC yang paling rendah [21]. *Akaike Information Criteria* (AIC) banyak digunakan pada model statistik untuk mengukur tingkat kesesuaian model. Pada saat membandingkan dua atau lebih sebuah model, model dengan nilai AIC paling rendah dianggap lebih mendekati data aktual [22].

$$AIC(P^*) = \frac{2p^*}{n} + \frac{-2 \ln L(P^*)}{n} \quad (8)$$

Keterangan

$L(P^*)$: nilai maksimum *likelihood*

p^* : jumlah parameter β , $p^* = 1, 2, \dots, p$

n : jumlah data

5. Uji diagnostik

Uji diagnostik dilakukan setelah uji signifikansi estimasi dari suatu parameter untuk membuktikan apakah model sudah cukup baik atau tidak [17]. Model akan dikatakan baik jika asumsi dari distribusi

normal dan residual *white noise* terpenuhi. Untuk mengetahui residual dikatakan *white noise* atau tidak dapat menggunakan Uji *Ljung-Box* sebagai berikut [19].

$$Q = n(n + 2) \sum_{k=1}^K \hat{\rho}_k^2 (n - k)^{-1} \quad (9)$$

Keterangan

n : banyak data

k : nilai lag

K : nilai maksimum lag

$\hat{\rho}_k$: nilai ACF

Sedangkan, untuk asumsi distribusi normal dengan menggunakan *Jarque Bera Test*. Metode ini berasal dari perbandingan seberapa jauh ukuran asimetri dan kurtosis yang berbeda dari karakteristik nilai distribusi normal. Kriteria uji yang digunakan adalah jika nilai $JB > \alpha = 0,05$ maka data berdistribusi normal dan begitu juga sebaliknya [23], [24].

$$JB = \frac{N}{6} SK + \frac{N}{24} KU \quad (10)$$

Keterangan

JB : *Jarque Bera*

SK : kemiringan

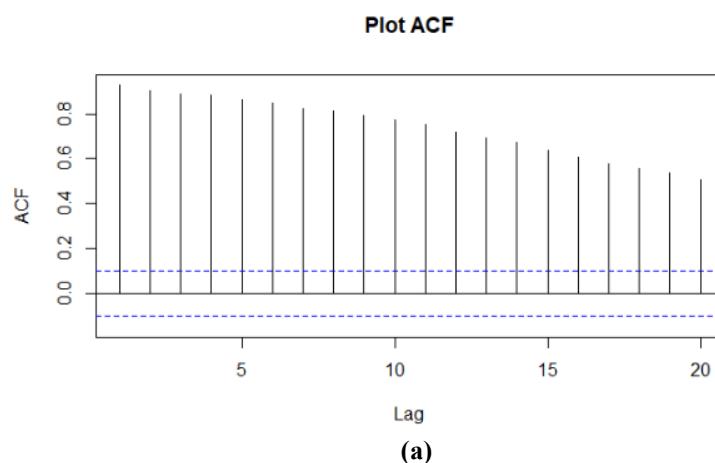
KU : ukuran kurtosis

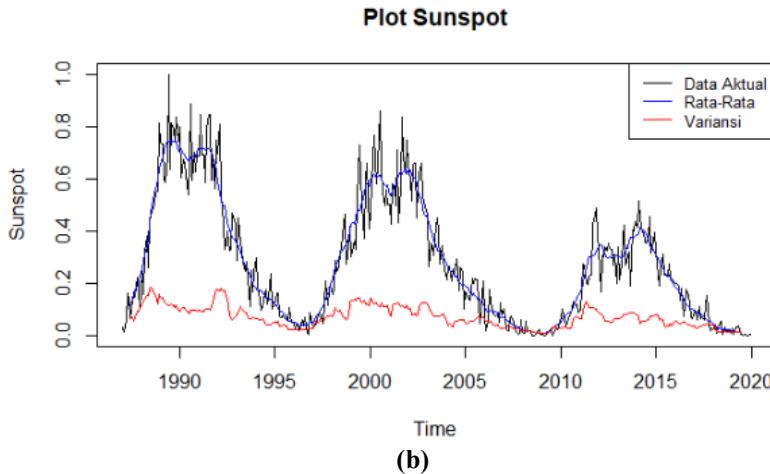
6. Data aktual yang sebelumnya dinormalisasi akan dikembalikan ke data aktual semula atau didenormalisasikan.
7. Model ARIMA yang sudah didapat kemudian digunakan untuk menentukan prediksi di masa mendatang. Prediksi dengan metode ini dikatakan baik daripada menggunakan model ekonometri tradisional [11].

3. HASIL DAN PEMBAHASAN

Pada penelitian ini, data yang diperoleh akan digunakan untuk memprediksi bilangan *sunspot* enam bulan berikutnya yaitu bulan 1 hingga bulan 6 tahun 2020.

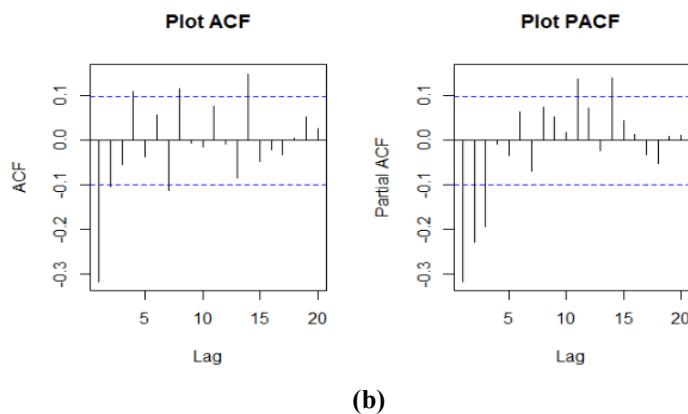
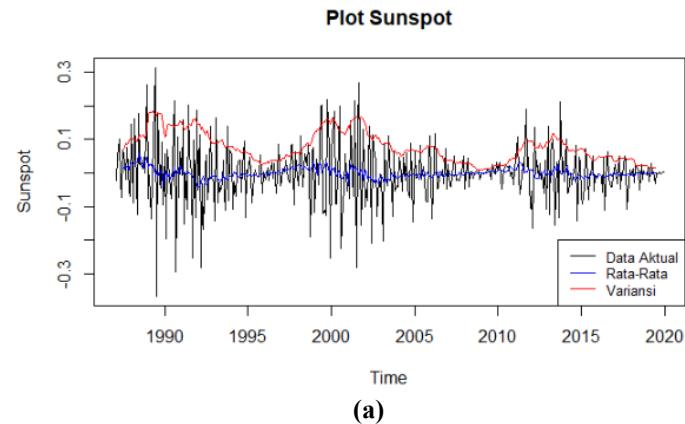
Berdasarkan data pada Tabel 1 yang sudah diperoleh, data akan dinormalisasi terlebih dahulu untuk mengisi data yang bernilai nol. Setelah data dinormalisasi kemudian dibuat plot data dan plot ACF untuk mengidentifikasi kestasioneran data.





Gambar 1. (a) Plot ACF, (b) Plot data bilangan sunspot

Pada Gambar 1 (a) terlihat bahwa plot ACF lag ke-1 hingga lag ke-20 keluar dari garis putus-putus atau garis signifikan, sehingga dapat dikatakan data tersebut tidak stasioner. Sedangkan pada **Gambar 1 (b)** dapat dilihat bahwa varians sudah konstan terhadap waktu. Kemudian pada data aktual terlihat bahwa data tidak konstan terhadap waktu. Lalu pada *mean* juga tidak konstan terhadap waktu dan bergerak mengikuti plot data aktual. Karena data aktual dan *mean* tidak konstan, maka data dikatakan tidak stasioner terhadap *mean*, sehingga perlu dilakukan *differencing* tingkat satu.



Gambar 2. (a) Plot sunspot yang sudah stasioner, (b) plot ACF dan PACF yang sudah stasioner

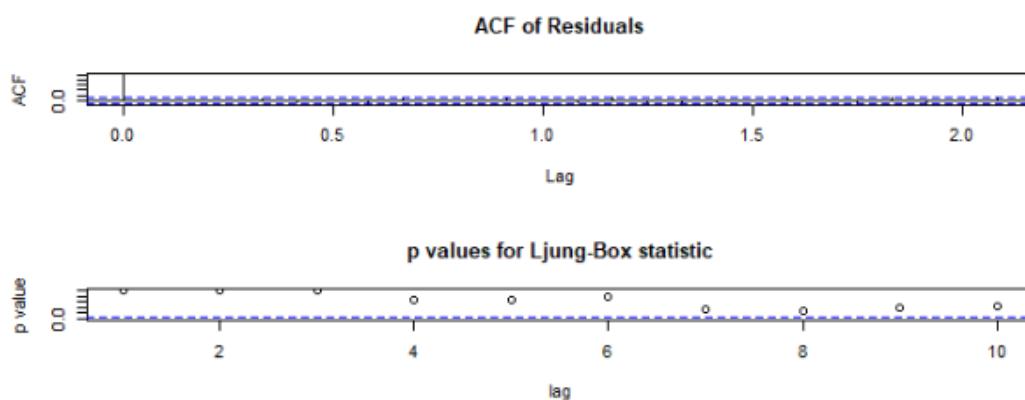
Pada Gambar 2 (a) dapat dilihat bahwa data aktual, *mean* dan varians sudah konstan terhadap waktu yang berarti data sudah stasioner. Karena data sudah stasioner maka dapat ditentukan model ARIMA(p, d, q) dengan orde p merupakan lag yang keluar dari signifikan pada plot PACF dan orde q merupakan lag yang keluar dari garis putus-putus/signifikan pada plot ACF serta d yang merupakan tingkat *differencing* pada data

yaitu satu. Dari Gambar 2 (b) didapatkan model sementara ARIMA yaitu ARIMA(3,1,2), ARIMA(3,1,1), ARIMA(2,1,2), dan ARIMA(2,1,1).

Tabel 2. Estimasi parameter

Model	Type	Estimasi Parameter		Kriteria
		AIC	p-value	
ARIMA(3,1,2)	AR(1)		0,0000	Signifikan
	AR(2)		0,4138	Tidak signifikan
	AR(3)	-881,61	0,0112	Signifikan
	MA(1)		0,0000	Signifikan
	MA(2)		0,0004	Signifikan
ARIMA(3,1,1)	AR(1)		0,1946	Tidak signifikan
	AR(2)		0,0225	Signifikan
	AR(3)		0,0310	Signifikan
	MA(1)		0,8360	Tidak signifikan
	MA(2)		0,0000	Signifikan
ARIMA(2,1,2)	AR(1)		0,0000	Signifikan
	AR(2)		0,0107	Signifikan
	MA(1)		0,0000	Signifikan
	MA(2)		0,0000	Signifikan
	AR(1)		0,6793	Tidak signifikan
ARIMA(2,1,1)	AR(2)	-877,5	0,1077	Tidak signifikan
	MA(1)		0,0000	Signifikan

Berdasarkan pada Tabel 2, setelah dilakukan estimasi parameter pada kelima model di atas diketahui bahwa model ARIMA(2,1,2) signifikan karena $p\text{-value} < \alpha = 0,05$ dan nilai AIC ARIMA(2,1,2) lebih rendah dari yang lainnya yaitu sebesar -884,87. Oleh karena itu, model ARIMA(2,1,2) akan digunakan untuk prediksi.

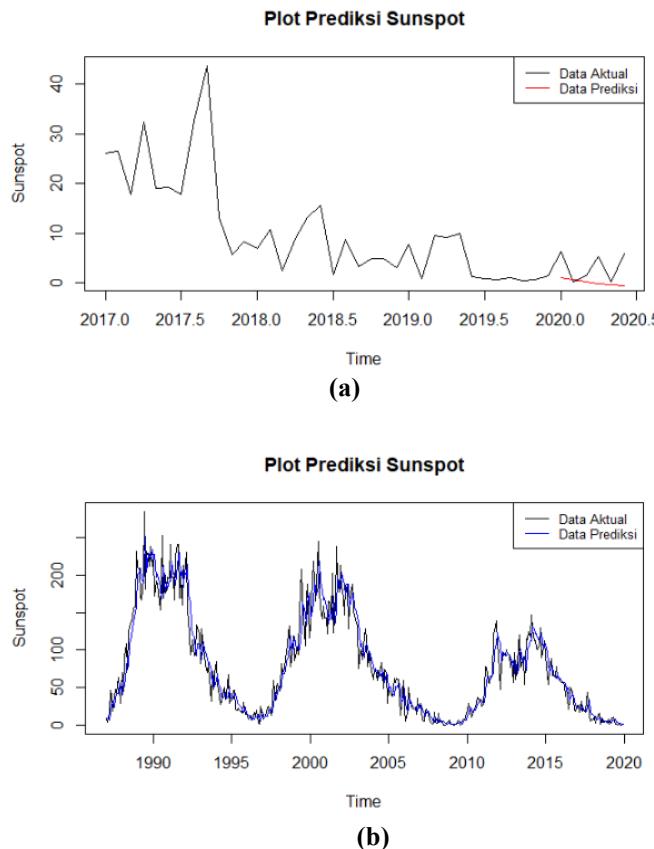


Gambar 3. Uji diagnostik

Pada Gambar 3 terlihat bahwa plot residual ACF tidak menunjukkan adanya lag yang keluar dari garis putus-putus atau garis signifikan, sehingga residualnya dikatakan *white noise*. Sedangkan pada plot statistik *Ljung-Box*, diketahui $p\text{-value} > \alpha = 0,05$ yang berarti tidak terdapat autokorelasi. Kemudian dilakukan uji normalitas dengan *Jarque Bera Test* dan didapatkan $p\text{-value}$ sebesar $1,125 \times 10^{-9} < \alpha = 0,05$ yang menunjukkan bahwa distribusi normal tidak terpenuhi. Sebelum dilakukan prediksi, data aktual yang sebelumnya dinormalisasi akan dikembalikan ke data aktual semula atau didenormalisasikan.

Tabel 3. Perbandingan data prediksi dan data aktual

Tahun	Bulan	Data Aktual	Data Prediksi
2020	1	6,2	1,0135777
2020	2	0,2	0,5536694
2020	3	1,5	0,1601057
2020	4	5,2	-0,1628287
2020	5	0,2	-0,4226707
2020	6	5,8	-0,6297593



Gambar 4 (a) Plot data prediksi dan aktual sunspot Tahun 2017-2020, (b) Plot data prediksi dan aktual sunspot Tahun 1987-2019

Tabel 3 merupakan prediksi bilangan sunspot pada bulan 1 hingga bulan 6 tahun 2020. Pada Tabel 3 terlihat hasil prediksi yang didapatkan berbeda jauh dengan data aktual sesuai dengan grafik yang berwarna merah pada Gambar 4 (a). Pada bulan kedua memiliki hasil prediksi yang mendekati data aktual daripada di bulan lainnya. Meskipun memiliki hasil prediksi yang jauh berbeda, akan tetapi memiliki grafik yang bergerak mengikuti data aktual seperti yang ditunjukkan pada Gambar 4 (b).

Hasil prediksi dengan metode ARIMA yang jauh berbeda juga terdapat pada penelitian tentang perbandingan metode ARIMA dengan RBFNN untuk meramalkan rata-rata banyaknya bilangan sunspot [4]. Pada penelitian ini data yang digunakan tidak berdistribusi normal, karena itu untuk penelitian selanjutnya diharapkan menggunakan metode nonparametrik seperti metode *Support Vector Regression* (SVR) agar mendapatkan hasil prediksi yang lebih baik [7].

4. KESIMPULAN

Berdasarkan hasil dan pembahasan prediksi bilangan sunspot menggunakan metode ARIMA dengan data bilangan sunspot setiap bulan yang dimulai dari tahun 1987 hingga tahun 2019 didapatkan 4 model ARIMA yaitu ARIMA(3,1,2), ARIMA(3,1,1), ARIMA(2,1,2), ARIMA(2,1,1). Dari keempat model tersebut diperoleh satu model tebaik yang digunakan untuk prediksi yaitu model ARIMA(2,1,2) dengan nilai AIC sebesar -884,87.

UCAPAN TERIMA KASIH

Terima kasih kepada Balai Pengamatan Antariksa dan Atmosfer Pasuruan yang telah memberikan kesempatan, waktu dan ilmu yang bermanfaat sehingga peneliti dapat menyusun jurnal ini. Tak lupa juga peneliti berterima kasih kepada dosen pembimbing, dosen lapangan serta semua pihak yang telah membantu menyusun jurnal ini. Peneliti berharap jurnal ini dapat bermanfaat bagi semua pihak.

DAFTAR PUSTAKA

- [1] D. Hasanah, R. A, "Pengelompokan Sunspot pada Citra Matahari dengan Menggunakan K-Means Clustering," *MathVisioN*, vol. 01, no. 02, pp. 72–78, 2019, [Online]. Available: url:<http://journal.unirow.ac.id/index.php/mv>.
- [2] S. Nisa', Estimator Kernel Epanechnikov dan Kernel Triangle pada Data Rata-Rata Bulanan Bilangan Sunspot, NOAA. Undergraduate [thesis]. Malang: Universitas Islam Negeri Maulana Malik Ibrahim, 2016. [Online]. Available: <http://etheses.uin-malang.ac.id/2895/>.
- [3] G. S. Budhi, R. Adipranata, M. Sugiarto, B. Anwar, and B. Setiahadi, "Pengelompokan Sunspot Pada Citra Digital Mahatari Menggunakan Metode Clustering Dbscan," *Semin. Nas. Apl. Teknol. Inf.* 2011, vol. 2011, no. Snati, pp. 17–18, 2011, [Online]. Available: <https://www.neliti.com/publications/176344/pengelompokan-sunspot-pada-citra-digital-mahatari-menggunakan-metode-clustering>.
- [4] M. A. Zufar, Perbandingan Metode ARIMA dengan RBFNN dalam Peramalan Rata-Rata Banyaknya Bilangan Sunspot. Undergraduate [thesis]. Malang: Universitas Islam Negeri Maulana Malik Ibrahim, 2018. [Online]. Available: <http://etheses.uin-malang.ac.id/13954/>.
- [5] Y. Monita, D. C. R. Novitasari, N. Widodo, and A. Z. Arifin, "Penggunaan Metode Backpropagation Untuk Peramalan Jumlah Ledakan Matahari (Flare)," *MathVisioN*, vol. 1, no. 02, pp. 67–71, 2019, [Online]. Available: url:<http://journal.unirow.ac.id/index.php/mv>.
- [6] U. Yus'an and E. Puspitaningrum, "Mendeteksi Aktivitas Matahari dengan Mengamati Evolusi Plage dan Sunspot Menggunakan Software Kesehatan," *Media Dirgant.*, vol. 9, no. 4, 2014, [Online]. Available: <https://majalah.lapan.go.id/index.php/md/article/download/245/232>.
- [7] S. Suwanto, Prediksi Bilangan Sunspot menggunakan Support Vector Regression (SVR). Undergraduate [thesis]. Surabaya: Universitas Islam Negeri Sunan Ampel, 2019. [Online]. Available: <http://digilib.uinsby.ac.id/id/eprint/38114>.
- [8] W. E. Cahyono, "Dampak Aktivitas Matahari Terhadap Kenaikan Temperatur Global," *J. Ber. Dirgant.*, vol. 11, no. 1, pp. 1–5, 2010, [Online]. Available: http://jurnal.lapan.go.id/index.php/berita_dirgantara/article/view/1159.
- [9] A. Lusiani, "Pemodelan Autoregressive Integrated Moving Average (ARIMA) Curah Hujan Di Kota Bandung," *Sigma-Mu*, vol. 3, pp. 9–25, 2011, [Online]. Available: <https://jurnal.polban.ac.id/sigmamu/article/view/874>.
- [10] B. A. Marzouk, "Statistical method to predict the sunspots number," *NRIAG J. Astron. Geophys.*, vol. 7, no. 2, pp. 175–179, 2018, [Online]. Available: <https://doi.org/10.1016/j.nrjag.2018.08.001>.
- [11] H. Hartati, "Penggunaan Metode Arima Dalam Meramal Pergerakan Inflasi," *J. Mat. Sains dan Teknol.*, vol. 18, no. 1, pp. 1–10, 2017, [Online]. Available: <http://jurnal.ut.ac.id/index.php/jmst/article/view/163>.
- [12] N. Salwa, N. Tatsara, R. Amalia, and A. F. Zohra, "Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average)," *J. Data Anal.*, vol. 1, no. 1, pp. 21–31, 2018, [Online]. Available: <http://www.jurnal.unsyiah.ac.id/JDA/article/view/11874>.
- [13] A. A. Willyiana, M. Y. Darsyah, and U. M. Semarang, "Perbandingan Metode ARIMA Dan Moving Average Pada Kasus Harga Gula Pasir Di Jakarta," *Prose. Semin. Nas. Mhs. Unimus*, vol. 1, pp. 361–367, 2018, [Online]. Available: https://www.researchgate.net/profile/Moh_Darsyah/publication/339350281_Perbandingan_Metode_ARIMA_Dan_MOVING_AVERAGE_Pada_Kasus_Harga_Gula_Di_Jakarta/links/5e4ca3bf92851c7f7f457594/Perbandingan-Metode-ARIMA-Dan-MOVING-AVERAGE-Pada-Kasus-Harga-Gula-Di-Jakarta.pdf.
- [14] S. Chattopadhyay, D. Jhajharia, and G. Chattopadhyay, "Trend estimation and univariate forecast of the sunspot numbers: Development and comparison of ARMA, ARIMA and Autoregressive Neural Network models," *Comptes Rendus - Geosci.*, vol. 343, no. 7, pp. 433–442, 2011, [Online]. Available: <http://dx.doi.org/10.1016/j.crte.2011.07.008>.
- [15] D. A. Nasution, H. H. Khotimah, and N. Chamidah, "Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN," *Comput. Eng. Sci. Syst. J.*, vol. 4, no. 1, p. 78, 2019, [Online]. Available: <https://jurnal.unimed.ac.id/2012/index.php/cess/article/view/11458>.
- [16] N. Chamidah, . W., and U. Salamah, "Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi," *J. Teknol. Inf. ITSmart*, vol. 1, no. 1, p. 28, 2016, [Online]. Available: <https://jurnal.uns.ac.id/itsmart/article/view/582>.
- [17] M. L. Tauryawati and M. I. Irawan, "Perbandingan Metode Fuzzy Time Series Cheng dan Metode Box-Jenkins untuk Memprediksi IHSG," *J. Sains dan Seni ITS*, vol. 3, no. 2, pp. A34–A39, 2014, [Online]. Available: http://ejurnal.its.ac.id/index.php/sains_seni/article/view/7985.
- [18] R. N. Anityaloka and A. N. Ambarwati, "Peramalan Saham Jakarta Islamic Index Menggunakan Metode ARIMA Bulan Mei-Juli 2010," *Statistika*, vol. 1, no. 1, pp. 1–5, 2013, [Online]. Available: <http://103.97.100.145/index.php/statistik/article/view/733>.
- [19] W. H. Lailiyah and D. Manuharawati, "Penerapan Metode Autoregressive Integrated Moving Average (Arima) pada Peramalan Nilai Ekspor Di Indonesia," *Ilm. Mat.*, vol. 6, no. 3, pp. 45–52, 2018, [Online]. Available: <https://jurnalmahasiswa.unesa.ac.id/index.php/mathunesa/article/view/26373>.
- [20] A. Sutcliffe, "Time-series forecasting using fractional differencing," *J. Forecast.*, vol. 13, no. 4, pp. 383–393, 1994, [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1002/for.3980130404>.
- [21] R. Nurmala and D. Ispriyanti, "Analisis Faktor-Faktor Yang Mempengaruhi Indeks Pembangunan Manusia (IPM)," *Bul. Ilm. Math.Stat dan Ter.*, vol. 8, no. 1, pp. 111–120, 2019, [Online]. Available: <http://ejournal-s1.undip.ac.id/index.php/gaussian>.
- [22] P. Mondal, L. Shit, and S. Goswami, "Study of Effectiveness of Time Series Modeling (Arima) in Forecasting Stock Prices," *Int. J. Comput. Sci. Eng. Appl.*, vol. 4, no. 2, pp. 13–29, 2014, [Online]. Available: <https://www.researchgate.net/publication/276197260>.
- [23] C. Domaniński, "Properties of Jarque-Bera test," *Acta Univ. Lodz. Folia Oeconomica*, vol. 235, no. 6 2, 2010, [Online]. Available: http://cejsh.icm.edu.pl/cejsh/element/bwmeta1.element.hdl_11089_340.
- [24] R. Wahyudi and L. Martha, "Analisis Modal Intelektual Dan Kinerja Keuangan Serta Pengaruhnya Terhadap Nilai Perusahaan," *INA-Rxiv*, 2019, [Online]. Available: <https://osf.io/preprints/inarxiv/j5e9u/>.

