

PREDIKSI JANGKA PENDEK BULANAN JUMLAH *FLARE* DENGAN MODEL ARIMA (p,d,[q]), (P,D,Q)¹³²

Nanang Widodo
Peneliti Stasun Pengamat Dirgantara Watukosek, LAPAN

ABSTRACT

The time series of the monthly number of flares from Januari 1965 to December 2004 is analyzed by ARIMA models. It is suggested that there is any auto correlation between monthly data in regular and seasonal order (11 years solar activity cycle) in the ARIMA (p, d, foj), (P, D, Q)»" models. After several of feasibility test had succeeded and the assumption of stationary in mean and variance was obtained, we can determine the best model i.e; ARIMA (1, 1, [13]) (0, 1, 1)«2 and ARIMA (0, 1, [13]) (0, 1, 1)«M. From this models, we can use to predict the monthly number of flares.

ABSTRAK

Paper ini menganalisis suatu model time series ARIMA berdasarkan data bulanan jumlah *flare* dari Januari 1965 sampai 2004 yang berbentuk time series, selanjutnya dilakukan analisis statistik pada model tersebut. Dengan dugaan adanya auto-korelasi dalam order reguler dan order musiman (siklus 11 tahun aktivitas matahari), dibangun model ARIMA (p, d, [q]), (P, D, Q)¹³². Setelah melalui beberapa uji kelayakan yang disyaratkan dalam menentukan model terbaik didapatkan ARIMA (1, 1, [13])(0, 1, **ljwa** dan ARIMA (0, 1, [13]) (0, 1, 1)132. Selanjutnya model tersebut akan digunakan untuk prediksi jangka pendek bulanan jumlah *flare*, dengan batas kesalahan tertentu.

Kata kunci: *Order reguler (Sub-rnusiman), Order musiman*

1 PENDAHULUAN

Pada tahun 1927 Yule telah memelopori analisis *time series* pada data bilangan *sunspot* sebagai fenomena alam yang penting (Priestley, 1996). Para ilmuwan mempercayai bahwa bilangan *sunspot* yang mempunyai panjang siklus 11 tahun dapat mempengaruhi iklim di Bumi dan beberapa aktivitas manusia (Wei, 1990), Data jumlah *flare* yang digunakan pada penelitian ini juga mempunyai sifat yang serupa dengan data *sunspot* yaitu bersiklus 11 tahunan (132 bulan). Berdasarkan kondisi data jumlah *flare* Januari 1965 - Nopember 2000 berbentuk *time series*, maka akan dilakukan pendekatan model ARIMA. Karena diduga ada korelasi parsial diantara data

tersebut pada order reguler (sub-musiman) dan order musiman maka akan dibangun suatu model ARIMA (p, d, [q]), (P, D, Q)¹³².

Dalam beberapa penelitian data jumlah/fare sebelumnya tidak pernah dilakukan analisis *time series* pada order musiman. Berdasarkan analisis awal pada penelitian (Widodo, 2002) dari plot grafik *Auto Correlation Function*, ACF dan *Partial Auto Correlation Function*, PACF dinyatakan bahwa sangat perlu dilakukan analisis tambahan pada order musiman.

Melalui pendekatan model ARIMA dengan penyelesaian dua order tersebut dan beberapa tahap pengujian terhadap model, sehingga secara statistika model dinyatakan valid dan secara fisika dapat memberikan hasil peramalan jumlah *flare* yang mendekati kondisi sebenarnya (data NOAA). Bila kondisi ini terpenuhi, maka model tersebut dapat digunakan sebagai alat untuk memperoleh informasi lebih dini tentang aktivitas matahari.

2 TEORI

Bila terdapat data $\{X_t\}$ yang bersifat stasioner dalam mean dan variansi, maka dapat dilakukan pemodelan *time series linier*. Data dinyatakan stasioner jika distribusi gabungan

$$F\{X_{t_1}, X_{t_2}, \dots, X_{t_n}\} = F\{X_{t_1+k}, X_{t_2+k}, \dots, X_{t_n+k}\} \quad (2-1)$$

Dimana *Autocorrelation Function*, ACF, ρ_k adalah korelasi antara X_t vs X_{t+k}

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (2-2)$$

Proses autoregresi (AR) merupakan regresi antara X_t dengan nilai X_t sebelumnya, atau regresi dengan dirinya sendiri. Proses $\{X_t\}$ dikatakan suatu proses auto regresi order p jika (Box, 1994).

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t \quad (2-3)$$

$$\text{atau } (1 - \phi_1 B - \dots - \phi_p B^p) X_t = \phi(B) X_t = a_t$$

AR(1)

ACF untuk model AR(1) didapatkan dari

$$E(X_{t-k} X_t) = \phi_1 E(X_{t-k} X_{t-1}) + E(X_{t-k} a_t)$$

$$\gamma_k = \phi_1 \gamma_{k-1} \quad ; k \geq 1 \quad ; \quad \rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\phi_1 \gamma_{k-1}}{\gamma_0} = \phi_1^k \quad (2-4)$$

dengan

γ_k adalah autokovariansi antara X_t dan X_{t+k} , $\text{cov}(X_t, X_{t+k})$

ρ_k adalah autokorelasi antara X_t dan X_{t+k} , $\text{corr}(X_t, X_{t+k})$

ϕ_{ki} = parameter regresi ke i .

$$\text{var}(X_t) = \text{var}(X_{t+k}) = \gamma_0$$

PACF

Fungsi autokorelasi parsial adalah autokorelasi antara X_t dan X_{t+k} setelah kebergantungan linier pada variabel-variabel diantaranya, X_{t+1} , X_{t+2} , X_{t+k-1} ditinggalkan.

PACF untuk model AR(1) didapatkan dari parameter regresi ke 1 (lag 1) sampai dengan k (lag k) ditetapkan ketentuan berikut:

$$\phi_{kk} \begin{cases} \rho_1 = \phi_1 & \text{untuk } k=1 \\ \rho_1 = 0 & \text{untuk } k \geq 2 \end{cases} \quad (2-5)$$

artinya nilai autokorelasi lag 1 (ρ_1) signifikan dengan besarnya ϕ_1 , sedangkan lainnya berada di bawah batas selang kepercayaan atau $\rho_1 = 0$.

Proses Moving Average (MA)

Proses moving average adalah proses X_t yang bergantung linier pada sejumlah q pembobot dari a (Wei, 1990). Proses MA order q dinyatakan sebagai berikut:

$$X_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2-6)$$

secara teori berdasarkan pada nilai ekspektasi fungsi, diperoleh

$$\text{MA}(1) : \quad \text{ACF} : \quad \rho_k = \begin{cases} \frac{-\theta_1}{1+\theta_1^2} & k=1 \\ 0 & k>1 \end{cases} \quad (2-7)$$

$$\text{PACF} : \quad \phi_{kk} = \frac{-\theta_1^k (1-\theta_1^2)}{1-\theta_1^{2(k+1)}} ; k \geq 1 \quad (2-8)$$

Dalam pemodelan ARIMA ($p, d, [q]$), (P, D, Q)¹³² digunakan beberapa tahapan berikut:

- Identifikasi data dengan plot Fungsi Auto-Korelasi (ACF) dan Parsial Auto-Korelasi pada order reguler dan order musiman.
- Mengestimasi parameter model, dengan metode *Maximum Likelihood Estimation*, MLE.

Estimator MLE = nilai-nilai parameter yang sesuai dengan data dan memaksimalkan fungsi likelihood.

$$P(a|\phi, \mu, \sigma_a^2) = (2\pi\sigma_a^2)^{-(n-1)/2} \exp\left(-\frac{1}{2\sigma_a^2} \sum_{t=2}^n a_t^2\right) \quad (2-9)$$

- Menguji tingkat signifikansi dari parameter dan menguji kenormalan residual model.
- Konstruksi model *Autoregressive Integrated Moving Average* atau ARIMA ($P \gg d \gg [q]$) ($P \gg D, Q$)¹³². Proses kombinasi model AR(p) dan MA(q) merupakan suatu cara mengatasi terbentuknya salah satu dari model AR(p) atau MA(q) dengan jumlah parameter p atau q yang besar sekali (model dengan orde tinggi). Parameter dalam jumlah besar akan mengurangi efisiensi dalam mengestimasi model. Dengan demikian model dapat dituliskan menjadi ARMA (p, q) berikut

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

atau $\phi_p(B)X_t = \theta(B)_q a_t$ (2-10)

dengan

$\phi_p(B)$ adalah nilai parameter ke p dari bagian model AR

$\theta(B)_q$ adalah nilai parameter ke q dari bagian model MA

Berdasarkan nilai-nilai parameter yang signifikan dari persamaan (2-10), maka dikonstruksikan beberapa model dugaan ARIMA ($p, d, [q]$), (P, D, Q)¹³². Untuk mendapatkan model terbaik dari beberapa model dugaan ARIMA ($p, d, [q]$), (P, D, Q)¹³² yang dibangun (Tabel 4-1 dan Tabel 4-2), diberikan syarat pemilihan model terbaik, yaitu kriteria AIC dan SBC.

Akaike's Information Criterion (AIC)

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \quad (2-11)$$

Schwartz's Bayesian Criterion (SBC)

$$SBC(M) = n \ln \hat{\sigma}_a^2 + M \ln n \quad (2-12)$$

dengan

M = jumlah parameter dalam model

n = jumlah pengamatan efektif

- Pengembangan model ARIMA ($p, d, [q]$), (P, D, Q)¹³² untuk prediksi *flare* jangka pendek.

Pada makalah ini digunakan contoh langkah peramalan dari model AR(1), (detail Box, 1994) dengan menuliskan persamaan nilai taksiran AR(1) sebagai:

$$\hat{X}_t(1) = \mu + \phi[X_t - \mu] \quad (2-13)$$

artinya bagian ϕ deviasi dari *mean* proses ditambah *mean* proses untuk meramalkan nilai proses mendatang. Dengan kesalahan peramalan satu langkah, $e_t(1)$

$$e_t(1) = X_{t+1} - \hat{X}_t(1) \quad (2-14)$$

- Membandingkan jumlah *flare* bulanan hasil prediksi dengan kondisi *real* jumlah *flare* bulanan pada data NOAA.

3 DATA

Data yang digunakan pada penelitian ini adalah data bulanan jumlah *flare* dari *bulletin Solar Geophysical Data*, NOAA sebanyak 431 data (Januari 1965 - Nopember 2000), plot data ini dinyatakan pada Gambar 5-2, warna biru (data asli). Karena data tersebut bersifat *time series*, maka akan dilakukan analisis auto korelasi antar data pada order reguler (sub-musiman) dan order musiman (siklus 11 tahunan) dengan suatu model ARIMA (p, d, [q]), (P, D, Q)ⁱ³².

4 HASIL

Setelah melalui beberapa tahap seleksi plot ACF/PACF dari data dan pengujian awal dalam pemodelan ARIMA didapatkan 4 model alternatif, yaitu model A, (ARIMA (1, 1, [13]) (0, 1, ip2), model B (ARIMA (1, 1,[26]) (0, 1, 1)132), model C (ARIMA (0, 1, 2) (0, 1, 1)*32) dan model D (ARIMA (0, 1, [13]) (0, 1, 1)^).

Selanjutnya akan dijelaskan kontribusi setiap parameter dari keempat model yang telah diperoleh.

Tabel4-1:CONTOH HASIL SAS UNTUK MODEL ARIMA (1,1,[13])(0,1,1)132

Maximum Likelihood Estimation				
Approx.				
Parameter	Estimate	Std Error	T Ratio	Lag
MA1,1	-0.02896	0.0475	-0.61	13
MA2,1	0.99864	102.81	0.01	132
AR1,1	-0.37836	0.04258	-8.89	1
Variance Estimate	= 0.4071			
Std Error Estimate	= 0.6380			
AIC	= 710.9			
SBC	= 721.9			
Number of Residuals	= 287			
Correlations of the Estimates				
Parameter	MA1,1	MA2,1	AR1,1	
MA1,1	1.000	0.006	0.056	
MA2,1	0.006	1.000	0.109	
AR1,1	0.056	0.109	1.000	

Hasil penghitungan *model A* (Tabel 4-1) menunjukkan bahwa analisis parameter pada order reguler MA[13] memberikan hasil yang cukup signifikan dengan nilai AIC dan SBC yang relatif kecil. Akan tetapi pada analisis parameter order reguler suku AR(1) tidak signifikan (T-ratio = 8,88) selain itu residual model tidak memenuhi syarat dalam distribusi Normal.

Model ini dapat juga dipertimbangkan untuk model peramalan, hal ini bila dilihat dari tingkat akurasi dari 6 buah data dari 11 data hasil peramalan mempunyai tingkat ketepatan > 75 %.

Tabel 4-2: CONTOH HASIL SAS UNTUK MODEL D,
ARIMA(0,1,[13])(0,1,1)132

Maximum Likelihood Estimation				
Parameter	Estimate	Std Error	T Ratio	Lag
MA1,1	-0.02713	0.04772	-0.57	13
MA2,1	0.99952	185.8669	0.01	132
Approx.				
Variance Estimate	= 0.47812736			
Std Error Estimate	= 0.69146754			
AIC	= 756.19874			
SBC	= 763.517705			
Number of Residuals	= 287			
Correlations of the Estimates				
Parameter	MA1,1	MA2,1		
MA1,1	1.000	-0.073		
MA2,1	-0.073	1.000		

Sehingga dapat dikatakan bahwa hasil prediksi model ini telah mengikuti *trend* fluktuasi jumlah *flare* bulanan data NOAA, meskipun rata-rata kesalahan penyimpangan peramalan terhadap model (% error) = 50,5 %. (Tabel 5-2).

Hasil penghitungan model B (Tabel 5-1) memberikan nilai AIC, SBC dan T-ratio yang sebanding dengan model A, karena hasil analisis order sub-musiman MA([26]) merupakan pengaruh akumulasi dari lag 13 (data bulan ke 13 dan bulan ke 26 dari jumlah *flare* bulanan). Sehingga model ini akan tereliminasi dari perbandingan model-model di atas. Pada model ini didapatkan 6 data dari 11 data peramalan yang mempunyai tingkat ketepatan > 75 %. Tetapi rata-rata kesalahan penyimpangan peramalan terhadap model (% error) = 54,1 %. (Tabel 5-2).

Khusus model C, telah digunakan dalam model peramalan *flare* oleh Widodo, (2002, a). Pada model ini, diasumsikan bahwa lag 13 dan 26 yang signifikan dianggap sebagai penyimpangan, sehingga tidak dimasukkan dalam

analisis order sub-musiman. Hasil analisis model C ini menunjukkan sifat efisien tetapi bias pada hasil peramalannya dengan rata-rata kesalahan penyimpangan peramalan terhadap data NOAA (% error) = 31.5 %. Tetapi hanya ada 3 data dari 11 data hasil peramalan yang mendekati data NOAA dengan tingkat ketepatan peramalan > 75 % (Tabel 5-2).

Hasil penghitungan model D (Tabel 5-1) menunjukkan bahwa tanpa kontribusi parameter AR(p), nilai AIC, SBC menjadi semakin besar. Pada Tabel 4-2 tampak dua parameter MA[13] di order reguler dan MA[1] di order musiman adalah signifikan, sehingga model ini layak digunakan dalam peramalan jumlah flare. Tetapi hasil peramalan menunjukkan ada 4 buah data dari 11 data peramalan yang mempunyai tingkat ketepatan > 75 %. Sedangkan rata-rata kesalahan penyimpangan peramalan terhadap data NOAA (% error) = 36.7 %. Ini membuktikan bahwa peran parameter MA[13] pada order sub-musiman sangat penting dalam menjelaskan keragaman data yang menunjukkan adanya sifat auto korelasi antara lag 1 dengan 13 dan seterusnya.

5 PEMBAHASAN

Berdasarkan pertimbangan nilai AIC, SBC, peran parameter MA[13] pada *order reguler* (sub-musiman), hasil rata-rata kesalahan penyimpangan peramalan terhadap data NOAA, maka dinyatakan ada dua model yang cukup representatif dapat mengikuti sifat fluktuatif dari data jumlah flare yaitu ARIMA (1, 1, [13]) (0, 1, 1) pada (model A) dan ARIMA (0, 1, [13]) (0, 1, 1)¹³² (model D).

5.1 Pada Model ARIMA(1,1,[13])(0,1,1)¹³² Terdapat Parameter-Parameter antara lain

Order reguler:

Parameter AR[1] = -0.37836, MA[13] = -0.02896 (order sub-musiman)

Order musiman 132 bulan (siklus 11 tahun):

Parameter MA[1] = 0.99864

Selain itu dilakukan differensi 1 reguler, differensi 1 musiman 132 bulan (siklus 11 tahun). Maka persamaan model ARIMA(1,1,[13])(0,1,1)¹³² dapat dituliskan:

$$(1 - \phi B)(1 - B)(1 - B^{132}) X_t = (1 - \theta B^{13}) (1 - \Theta B^{132}) e_t$$

$$(1 - \phi B)(1 - B - B^{132} + B^{133}) X_t = (1 - \theta B^{13}) (1 - \Theta B^{132}) e_t$$

$$(1 - B - B^{132} + B^{133} - \phi B + \phi B^2 + \phi B^{133} - \phi B^{134}) X_t = e_t - \theta e_{t-13} - \Theta e_{t-132} + \theta \Theta e_{t-145}$$

$$X_t - X_{t-1} - X_{t-132} + X_{t-133} - \phi X_{t-1} + \phi X_{t-2} + \phi X_{t-133} - \phi X_{t-134} = e_t - \theta e_{t-13} - \Theta e_{t-132} + \theta \Theta e_{t-145}$$

$$X_t = (1 + \phi) X_{t-1} + \phi X_{t-2} + X_{t-132} - (1 + \phi) X_{t-133} + \phi X_{t-134} + e_t - \theta e_{t-13} - \Theta e_{t-132} + \theta \Theta e_{t-145}$$

atau

$$\begin{aligned}
 X_t &= (1 - 0.37836) X_{t-1} - 0.37836 X_{t-2} + X_{t-132} - (1 - 0.37836) X_{t-133} - 0.37836 X_{t-134} + \\
 &\quad e_t + 0.02896 e_{t-13} - 0.99864 e_{t-132} + (-0.02896) * (0.99864) e_{t-145} \\
 X_t &= 0.62164 X_{t-1} - 0.37836 X_{t-2} + X_{t-132} - 0.62164 X_{t-133} - 0.37836 X_{t-134} + \\
 &\quad e_t + 0.02896 e_{t-13} - 0.99864 e_{t-132} - 0.02892 e_{t-145} \tag{5-1}
 \end{aligned}$$

artinya,

data sekarang (X_t) = 0.62164 kali data X_{t-1} (data 1 bulan sebelum X_t) dikurangi 0.37836 kali data X_{t-2} (data 2 bulan sebelum X_t) ditambah data X_{t-132} (data 132 bulan sebelum X_t) dikurangi 0.62164 kali data X_{t-133} (data 133 bulan sebelum X_t) dikurangi 0.37836 kali data X_{t-134} (data 134 bulan sebelum X_t) ditambah kesalahan sekarang (e_t) ditambah 0.02896 kali e_{t-13} (nilai kesalahan 13 bulan sebelum e_t) dikurangi 0.99864 kali e_{t-132} (nilai kesalahan 132 bulan sebelum e_t) dan dikurangi 0.02892 kali e_{t-145} (nilai kesalahan 145 bulan sebelum e_t).

5.2 Pada Model ARIMA(0,1,[13])(0,1,1)¹³² Terdapat Parameter-parameter antara lain

Order reguler.

Parameter MA[13] = -0.02713 (order sub-musiman)

Order musiman 132 bulan (siklus 11 tahun):

Parameter MA[1] = 0.99952

Selain itu dilakukan differensi 1 reguler, diferensi 1 musiman 132 bulan (siklus 11 tahun). Maka persamaan model ARIMA (0, 1, [13]) (0, 1, 1)¹³² dapat dituliskan:

$$\begin{aligned}
 (1 - B)(1 - B^{132}) X_t &= (1 - \theta B^{13}) (1 - \Theta B^{132}) e_t \\
 (1 - B - B^{132} + B^{133}) X_t &= (1 - \theta B^{13}) (1 - \Theta B^{132}) e_t \\
 (1 - B - B^{132} + B^{133}) X_t &= e_t - \theta e_{t-13} - \Theta e_{t-132} + \theta \Theta e_{t-145} \\
 X_t - X_{t-1} - X_{t-132} + X_{t-133} &= e_t - \theta e_{t-13} - \Theta e_{t-132} + \theta \Theta e_{t-145} \\
 X_t &= X_{t-1} + X_{t-132} - X_{t-133} + e_t - \theta e_{t-13} - \Theta e_{t-132} + \theta \Theta e_{t-145} \tag{5-2} \\
 X_t &= X_{t-1} + X_{t-132} - X_{t-133} + e_t - 0.02713 e_{t-13} - 0.99952 e_{t-132} + 0.02713 e_{t-145}
 \end{aligned}$$

artinya,

data sekarang (X_t) = data X_{t-1} (data 1 bulan sebelum X_t), ditambah data X_{t-132} (data 132 bulan sebelum X_t), dikurangi data X_{t-133} (data 133 bulan sebelum X_t), ditambah kesalahan sekarang (e_t), ditambah 0.02713 kali nilai e_{t-13} (nilai kesalahan 13 bulan sebelum e_t), dikurangi 0.99952 kali e_{t-132} (nilai kesalahan 132 bulan sebelum e_t) dan dikurangi 0.02711 kali e_{t-145} (nilai kesalahan 145 bulan sebelum e_t).

Tabel 5-1:PERBANDINGAN MODEL-MODEL DUGAAN

Model	AIC	SBC	T-rasio	Lag±100	Lag±150	WN/TWN	Test Norm Residua
1	2	3	4	5	6	7	8
Model A	710.9	721.9	S	108.7	220.9	WN	TN
Model B	711.4	722.4	TS	120.3	223.4	WN	TN
Model C	658.0	669.0	TS	67.0	162.0	WN	TN
Model D	756.2	763.5	S	141.2	303.9	WN	TN

Keterangan :

Kolom 1. Model ARIMA (*reguler*) (*seasonal*)^a dimulai dengan orde 1 sampai orde 4.

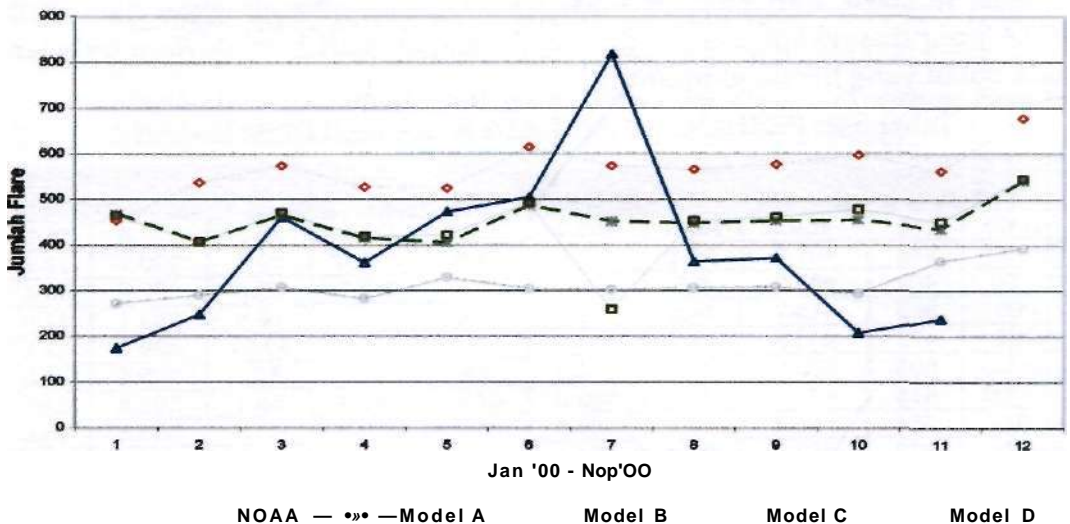
Kolom 2 dan 3. Hasil perhitungan *Swarth Bayesian Criteria* (SBC) dan *Akaike's Information Criteria*, AIC

Kolom 4. Keterangan signifikansi dari semua parameter model. Dikatakan tidak signifikan (TS) apabila T-rasio parameter < 1.96, dan signifikan (S) bila Trasio > 1.96 dari semua parameter model.

Kolom 5-6. Nilai χ^2_{df} hitung dari *residual* untuk kriteria (A= ± 100 df), (B= ± 150 df)

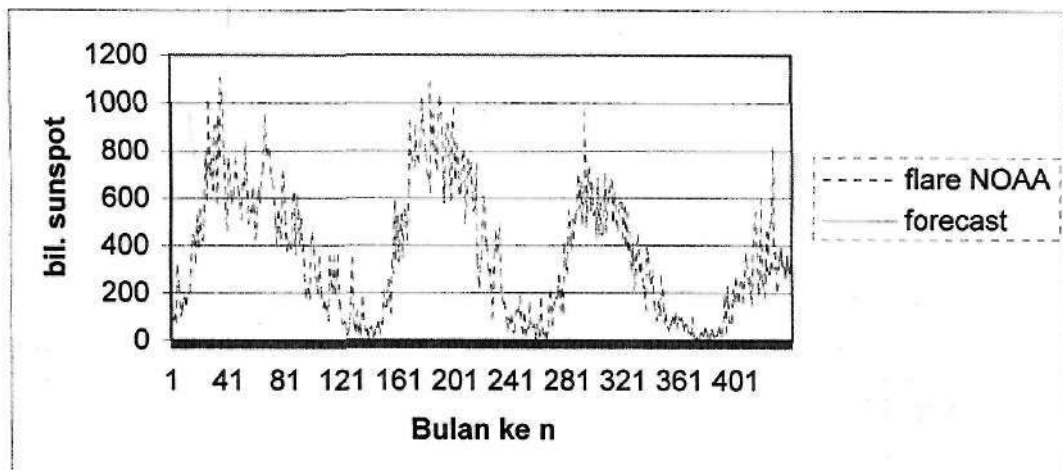
Kolom 7. Model dikatakan *white noise* (WN), apabila tidak menolak H_0 atau $\chi^2_{df}(\text{hitung}) < \chi^2_{df}(\text{tabel})$ dan tidak *white noise* (TWN) apabila tolak H_0 atau $\chi^2_{df}(\text{hitung}) > \chi^2_{df}(\text{tabel})$

Kolom 8. Pengujian normalitas *residual* dengan menggunakan uji *Ljung-Box*. Nilai p-value = $P(\chi^2_{\alpha} > \chi^2_{hit}) > 0.05$ berarti residualnya memenuhi asumsi kenormalan.



Gambar 5-1: Plot perbandingan data peramalan 4 model dengan data NOAA

Pada Gambar 5-1, tampak data Januari 2000 - Nopember 2000 NOAA yang didekati oleh 4 model dugaan berfluktuasi yang sangat variatif (berpola non linier), sehingga sulit untuk dapat diikuti secara baik oleh hasil peramalan 4 model ARIMA di atas. Pada bagian awal pembahasan telah dinyatakan bahwa model terpilih untuk dianalisis lebih lanjut adalah model A dan D, sehingga kejadian anomali besar bulan ke 7 pada model B dan C akan tereliminasi.



Gambar 5-2: Plot peramalan model ARIMA(1,1,[13])(0,1,ip2

Selanjutnya model D dinyatakan sebagai model yang representatif dibandingkan 3 model ARIMA lainnya dan dapat dipertimbangkan untuk peramalan jumlah *flare* bulanan, Gambar 5-2.

Karena, pendekatan analisis auto korelasi dalam model ARIMA untuk data jumlah *flare* berbentuk hubungan linier. Tampilan Tabel 5-2. merupakan ilustrasi numerik dari hasil prediksi dari 4 model dibandingkan data SGD NOAA yang dilengkapi dengan tingkat kesalahan dari jumlah *flare* bulanan pada bulan yang bersangkutan.

Tabel 5-2: PERBANDINGAN DATA NOAA DAN PERAMALAN

Bulan	Data NOAA	forecast Model A	% error	forecast Model B	% error	forecast Model C	% error	forecast Model D	% error
Jan '00	175	469.2	168.1	463.9	165.1	231.5	32.3	272.8	55.9
Peb '00	248	407.2	64.1	407.2	64.2	321.0	29.4	290.7	17.2
Mar '00	462	465.0	0.6	470.0	1.7	342.7	25.8	307.0	33.4
Apr '00	362	415.7	14.8	418.6	15.6	315.1	12.9	283.1	21.8
Mei '00	473	405.9	14.2	421.9	10.8	313.7	33.67	329.3	42.1
Jun '00	505	486.9	3.6	492.5	2.5	367.5	27.2	305.5	34.8
Juli '00	818	452.1	44.7	259.8	68.2	342.7	58.1	302.8	62.7
Ags '00	364	448.1	23.1	453.5	24.6	338.2	7.1	306.6	16.8
Sep '00	372	453.3	21.8	461.1	23.9	344.4	7.4	308.5	17.6
Okt '00	208	455.3	118.0	478.0	129.8	356.6	71.4	294.1	48.3
Nop '00	238	434.4	82.5	450.2	89.1	335.7	41.1	365.0	53.3
Rata-rata % error peramalan			50.5 %		54.1 %		31.5 %		36.7 %

6 KESIMPULAN

Berdasarkan analisis uji signifikansi parameter-parameter model di atas menunjukkan bahwa pendekatan model $ARIMA(p,d,[q])\{P,D,Q\}$ ⁸ hanya sesuai untuk data yang bersifat linier. Pada data jumlah *flare* mempunyai karakteristik fluktuasi yang non linier. Hal ini ditunjukkan oleh simpangan data *flare* pada daerah lembah-puncak siklus ke 20 - 23 mempunyai keragaman yang besar atau divergen. Tetapi diantara 4 model di atas ada dua model yang cukup representatif dalam mengikuti analisis parameter sub-musiman 13 bulanan atau orde $MA[13]$ dan kontribusi analisis parameter musiman 132 bulan (siklus 11 tahunan aktivitas matahari) dari data jumlah *flare* adalah $ARIMA(1,1,[13])(0,1,1)$ ³² dan $ARIMA(0,1,[13D(0,1)\gg 1])^m$. Bila kedua model tersebut dibandingkan dalam hal persentase rata-rata kesalahan peramalan, maka model $ARIMA(0,1,(13))(0,1,1)$ ¹³² dengan kesalahan peramalan 36.7 % merupakan model terbaik diantara 4 model dugaan $ARIMA(p, d, (qj), (P, D, Q)$ ¹³². Hal ini dibuktikan oleh hasil peramalan model 1 D yang menunjukkan ada 4 data peramalan yang mempunyai tingkat akurasi > 75 %.

Mengingat hasil analisis model belum efisien dan sedikit bias maka untuk mengatasi hal tersebut disarankan suatu pendekatan model $ARIMA$, model $VARIMA$, model time series bilinear atau model lainnya.

DAFTAR RUJUKAN

- Box, G.E.P., Jenkins, G.M. dan Reinsel, G. C, 1994. *Time Series Analysis, Forecasting and Control*, Third Edition, Prentice Hall International, Inc, New Jersey.
- Buletin Solar Geophysical Data Comprehensive Report, NOAA, April 2001 No. 668.
- Wei, W. W. S., 1990. *Time Series Analysis Univariate and Multivariate Methods*. Addison-Wesley Company Inc. New York.
- Widodo, N., 2002. *Analisis time series musiman model $ARIMA(0,1,2)(0,1,1)$ ³² untuk data frekuensi flare pada siklus ke 20-23*, Prosiding Seminar Nasional Matematika, ITS 2 Nopember 2002, hal 153-157.