

PEMODELAN VOLATILITAS DALAM ANALISIS DATA MAKROEKONOMI STUDI KASUS PADA INFLASI.

Isnandar Slamet¹⁾, Irwan Susanto²⁾, Wahyu Dewi Widyanti³⁾ dan Ismiyati Diniyah⁴⁾

1,2) *Jur. Matematika FMIPA UNS Surakarta.*

3) *Alumni Jur. Matematika FMIPA UNS*

4) *Mahasiswa Jur. Matematika FMIPA UNS*

Abstrak

Pemodelan volatilitas dapat dilakukan ketika terjadi heteroskedastisitas. Model *Autoregressive Conditional Heteroscedastic* (ARCH) dan model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) digunakan dalam generalisasi asumsi heteroskedastisitas.

Tujuan penelitian ini adalah menyusun model volatilitas untuk kasus inflasi serta ramalannya untuk beberapa periode ke depan.

Sebagai kesimpulan dapat dinyatakan proses heteroskedastisitas bersyarat yang paling sesuai untuk kasus inflasi adalah model ARIMA(3,2,(12)).

Kata kunci: *volatility, return, model Autoregressive Conditional Heteroscedastic (ARCH), model Generalized Autoregressive Conditional Heteroscedasticity (GARCH).*

PENDAHULUAN

Latar Belakang

Dalam analisis data makroekonomi sering terjadi keadaan heteroskedastisitas, yaitu eror yang memperlihatkan adanya periode-periode yang relatif tenang, kemudian diikuti periode-periode yang penuh gejolak (*volatility*) (Subanar, 2001). Banyak penelitian dilakukan berkaitan dengan variansi model runtun waktu yang tidak stabil, diantaranya Engle (1982), Enders (1995), Rockinger (2001), Wahyu Dewi Widyanti dan Isnandar Slamet (2009), dan Agung Ariyanto dan Isnandar Slamet (2009).

Model yang sering digunakan dalam memodelkan volatilitas adalah model *Autoregressive Conditional Heteroscedastic* (ARCH) (Engle, 1982). Pengembangan terhadap model ini dilakukan oleh Bollerslev (1986) yang dikenal dengan model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Menurut Bollerslev (1986), model GARCH memberikan hasil yang lebih baik daripada model ARCH.

Di negara berkembang seperti Indonesia, karena adanya berbagai gejolak, berakibat pada tingginya volatilitas nilai inflasi. Engle (1982) menunjukkan bahwa dalam menganalisa model inflasi, galat besar dan kecil sering terjadi pada kelompok yang berarti telah terjadi heteroskedastisitas, dalam arti variansi error ramalan tergantung pada ukuran gangguan sebelumnya. Menurut Tsay (2002), dengan memodelkan *volatility* dalam runtun waktu dapat menghasilkan efisiensi di dalam estimasi parameter dan keakuratan pada interval ramalan.

Rumusan masalah

Rumusan masalah dalam penelitian ini adalah bagaimana model ARCH dan GARCH yang sesuai untuk kasus inflasi dan bagaimana ramalan inflasi menggunakan model ARCH dan GARCH.

Tujuan dan Manfaat Penelitian

Tujuan penelitian ini adalah untuk mendapatkan model ARCH dan GARCH untuk kasus inflasi ramalan inflasi dan melakukan peramalan. Adapun manfaatnya adalah dapat menambah wawasan mengenai penerapan matematika khususnya analisis runtun waktu dalam menangani masalah sosial.

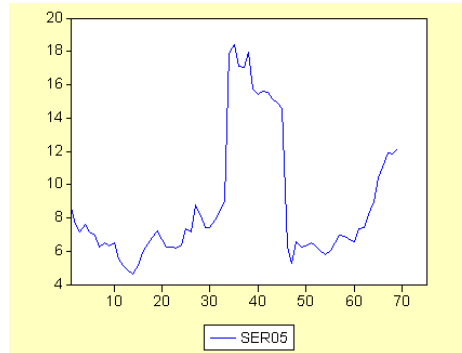
METODE PENELITIAN

Metode penelitian ini adalah studi literatur dan studi kasus. Data inflasi yang dimodelkan adalah data inflasi periode Januari 2003 sampai September 2008 yang merupakan data bulanan,

yang diambil dari *website* Bank Indonesia. Data yang diperoleh sebanyak 69. Analisis data dilakukan dengan bantuan *software E-views*.

HASIL PENELITIAN DAN PEMBAHASAN

Plot data dapat dilihat pada Gambar 1.



Gambar 1 Plot data inflasi

Stasioneritas data dapat dilihat melalui uji *Augmented Dickey-Fuller* atau disebut uji *unit root*. Hasil uji *unit root* dapat dilihat pada Tabel 1, yang dapat disimpulkan bahwa data inflasi belum stasioner.

Tabel 1 Uji *Unit root Augmented Dickey-Fuller* pada data inflasi

Null Hypothesis: SER01 has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.630234	0.4618
Test critical values: 1% level	-3.530030	
5% level	-2.904848	
10% level	-2.589907	

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


3.1 Membentuk Data Stasioner

3.1.1 Log Return

Salah satu usaha untuk menstasionerkan data adalah dengan mengubah data ke bentuk *log return*. *Log return* dirumuskan sebagai

$$r_t = \ln(Z_t / Z_{t-1})$$

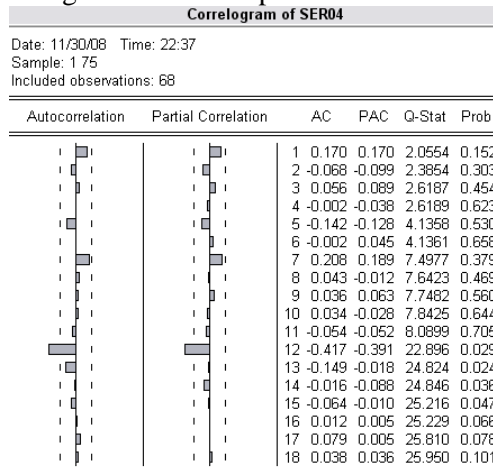
dengan Z_t adalah data pada waktu t . Plot *log return* dari data inflasi dapat dilihat pada Gambar 2.



Gambar 2 Plot log return

Uji *unit root* untuk data *log return* memberikan nilai lebih kecil dari tingkat signifikansi α 0,05, sehingga hipotesis nul ditolak. Jadi dapat disimpulkan bahwa data *log return* telah stasioner.

Nilai ACF dan PACF dari data *log return* perlu dilihat untuk pemodelan pada tahap selanjutnya, yaitu melihat model apa yang kemungkinan dapat digunakan. Plot ACF dan PACF beserta nilai statistik uji *Ljung-Box Q* statistik dapat dilihat pada Gambar 3. Nilai ACF dan PACF dari data *log return* menunjukkan nilai yang signifikan sama dengan nol untuk orde lag yang tinggi (sebelum lag-7), sehingga data *log return* tidak dapat dimodelkan ke dalam model runtun waktu.



Gambar 3 Plot ACF dan PACF data *log return*

3.1.2 Differencing (Pembedaan)

Cara lain yang dapat digunakan untuk mengubah data menjadi lebih stasioner adalah dengan *differencing* (pembedaan) yang dirumuskan sebagai

$$D^d(Z_t) = (1 - B)^d Z_t,$$

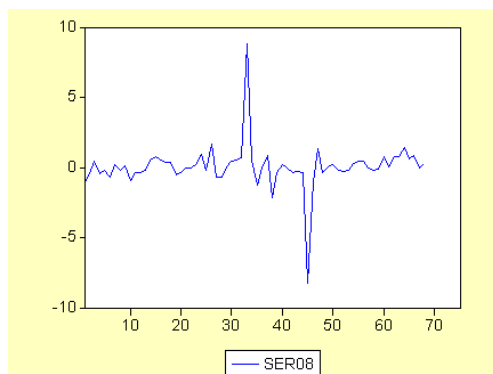
dengan Z_t adalah data runtun waktu pada waktu t , d adalah besarnya nilai pembedaan, dan B adalah operator *Backshift*.

Pembedaan Pertama

Pembedaan pertama dirumuskan sebagai

$$D(Z_t) = (1 - B) Z_t = Z_t - Z_{t-1}.$$

Jumlah data inflasi dengan pembedaan pertama berkurang dari data semula menjadi sebesar 68. Plot data inflasi dengan pembedaan pertama menunjukkan data sudah stasioner di dalam mean dan terdapat data dengan nilai yang terlihat jauh berbeda dengan nilai data yang lain (*outlier*). Plot data pembedaan dapat dilihat pada Gambar 4.



Gambar 4 Plot pembedaan pertama data inflasi

Uji *unit root* dilakukan untuk melihat apakah inflasi dengan pembedaan pertama benar sudah stasioner. Uji *unit root* memberikan nilai probabilitas sebesar 0,000 yang nilainya lebih kecil

dari tingkat signifikansi α 0,05, sehingga hipotesis nul ditolak. Jadi dapat disimpulkan bahwa data inflasi dengan pembedaan pertama telah stasioner.

Nilai ACF dan PACF dari data inflasi dengan pembedaan pertama menunjukkan nilai yang signifikan sama dengan nol untuk orde lag yang tinggi (sebelum lag-7), yang dapat dilihat juga pada nilai *Ljung-Box Q* statistik, sehingga data inflasi dengan pembedaan pertama tidak dapat dimodelkan ke dalam model runtun waktu ARMA.

Untuk mengatasi masalah maka perlu dilakukan pembedaan kedua. Pembedaan kedua dirumuskan sebagai

$$D^2(Z_t) = (1 - B)^2 Z_t = Z_t - 2Z_{t-1} + Z_{t-2}.$$

Hasil uji unit akar untuk data inflasi dengan pembedaan kedua menunjukkan data inflasi dengan pembedaan kedua telah stasioner. Plot nilai ACF dan PACF menunjukkan bahwa data inflasi dengan pembedaan kedua memiliki autokorelasi. sehingga data log *return* dengan pembedaan kedua dapat dimodelkan ke dalam model runtun waktu ARMA.

3.2 Pemodelan Mean Bersyarat

3.2.1 Identifikasi Awal

Data inflasi dengan pembedaan kedua telah terbukti memiliki autokorelasi, sehingga dapat dimodelkan ke dalam model runtun waktu ARMA(p,q). Identifikasi awal orde model ARMA ditentukan dengan melihat lag mana yang nilai ACF dan PACF yang signifikan tidak sama dengan nol. Terlihat bahwa nilai ACF signifikan pada lag-1, lag-2 dan lag-7, sedangkan nilai PACF signifikan untuk lag-1, lag-2, lag-6. Oleh karena itu, identifikasi awal model ARMA yang sesuai untuk data inflasi dengan pembedaan pertama adalah model ARMA(2(6),2(7)). Lag-12 tidak diikutsertakan karena lag tersebut merupakan orde lag yang rendah, sehingga dimungkinkan tidak begitu berpengaruh.

Hasil uji model ARMA(2(6),2(7)) dapat dilihat pada Tabel 2, dan Plot ACF dan PACF dapat dilihat pada Gambar 5. Model ARMA(2(6),2(7)) belum tepat digunakan untuk memodelkan mean bersyarat data inflasi dengan pembedaan kedua karena parameter-parameter model tersebut belum signifikan.

Uji *Breusch-Godfrey* dapat digunakan untuk melihat apakah residu suatu model sudah tidak memiliki autokorelasi. Uji serial korelasi *Breusch-Godfrey*, dengan hipotesis nul tidak ada autokorelasi pada residu model, memberikan nilai probabilitas 0,000019 yang nilainya lebih kecil dari tingkat signifikansi α 0,05, sehingga hipotesis nul ditolak. Jadi dapat disimpulkan masih ada autokorelasi dalam residu model. Hasil uji *Breusch-Godfrey* dapat dilihat pada Tabel 3.

Nilai ACF dan PACF residu model ARMA(2(6),2(7)) menunjukkan masih adanya autokorelasi yang signifikan pada lag-12 dalam residu model, sehingga autokorelasi pada lag tersebut juga perlu untuk dimodelkan. Plot ACF dan PACF residu model ARMA(2(6),2(7)) dapat dilihat pada Gambar 5.

Tabel 2 Estimasi model ARMA(2(6),2(7))

Dependent Variable: SER09
 Method: Least Squares
 Date: 12/08/08 Time: 11:24
 Sample(adjusted): 7 67
 Included observations: 61 after adjusting endpoints
 Convergence achieved after 142 iterations
 Backcast: OFF (Roots of MA process too large)

Variable	Coefficien	Std. Error	t-Statistic	Prob.
	t			
AR(1)	-0.743752	0.148773	-4.999238	0.0000
AR(2)	0.029056	0.145091	0.200262	0.8420
AR(6)	-0.099347	0.096782	-1.026503	0.3091
MA(1)	0.327544	0.150105	2.182092	0.0334
MA(2)	-1.175068	0.145724	-8.063677	0.0000
MA(7)	0.008066	0.140422	0.057443	0.9544

R-squared	0.636393	Mean dependent var	0.00082
Adjusted R-squared	0.603337	S.D. dependent var	2.22466
S.E. of regression	1.401119	Akaike info criterion	3.60560
Sum squared resid	107.9724	Schwarz criterion	3.81322
Log likelihood	-103.9708	Durbin-Watson stat	1.79108
<hr/>			
Inverted AR Roots	.51+.33i	.51 -.33i	-.10 -.63i
			-.10+.63i
Inverted MA Roots	-.78 -.26i	-.78+.26i	
	.93	.39	.10+.35i
			.10 -.35i
	-.29 -.22i	-.29+.22i	-1.26
Estimated MA process is noninvertible			

Tabel 3 Uji *Breusch-Godfrey* residu model ARMA(2(6),2(7))

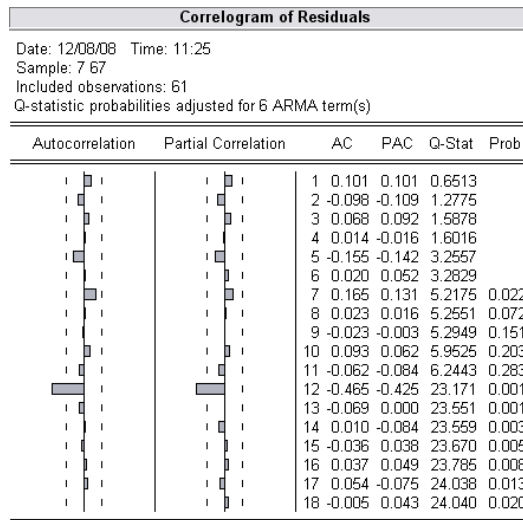
Breusch-Godfrey Serial Correlation LM Test:			
F-statistic	7.849649	Probability	0.00000
Obs*R-squared	29.78501	Probability	0.00004

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Date: 12/08/08 Time: 11:48
Presample missing value lagged residuals set to zero.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.462509	1.369673	0.337678	0.7370
AR(2)	0.440788	1.503026	0.293267	0.7706
AR(6)	-0.037986	0.285536	-0.133036	0.8947
MA(1)	18.00864	7.778640	2.315141	0.0248
MA(2)	14.63170	6.798795	2.152102	0.0363
MA(7)	-21.88556	9.726601	-2.250072	0.0290
RESID(-1)	-17.95525	8.492581	-2.114228	0.0396
RESID(-2)	-9.623672	4.493574	-2.141652	0.0372
RESID(-3)	-17.34637	7.642314	-2.269780	0.0277
RESID(-4)	-5.469728	2.565673	-2.131888	0.0381
RESID(-5)	-18.82638	8.262099	-2.278643	0.0271
RESID(-6)	-0.134022	0.185479	-0.722571	0.4734

R-squared	0.488279	Mean dependent var	0.07944
Adjusted R-squared	0.373403	S.D. dependent var	1.33907
S.E. of regression	1.059984	Akaike info criterion	3.12877

Sum squared resid	55.05476	Schwarz criterion	3.544028
Log likelihood	-83.42761	Durbin-Watson stat	1.961320



Gambar 5 Plot ACF dan PACF residu model ARMA(2(6),2(7))

3.2.2 Estimasi Ulang Pertama

Estimasi ulang model ARMA dari data inflasi dengan pembedaan kedua dilakukan dengan mengikutsertakan lag-12. Hasil output model ARMA(2(6),2(7)(12)) dapat dilihat pada Tabel 4. Hasil model ARMA(3(6),2(7)(12)) menunjukkan adanya nilai yang tidak signifikan untuk parameter AR pada lag-6 dan untuk parameter MA pada lag-2 dan lag-7, serta parameter MA yang diperoleh tidak invertibel. Oleh karena itu, model ARMA(2(6),2(7)(12)) tidak sesuai digunakan untuk memodelkan mean bersyarat dari data inflasi dengan pembedaan kedua.

Tabel 4 Estimasi model ARMA(2(6),2(7)(12))

Dependent Variable: SER09
Method: Least Squares
Date: 12/03/08 Time: 07:37
Sample(adjusted): 7 67
Included observations: 61 after adjusting endpoints
Convergence achieved after 18 iterations
Backcast: OFF (Roots of MA process too large)

Variable	Coefficien	Std. Error	t-Statistic	Prob.
AR(1)	-0.498000	0.159090	-3.130305	0.0028
AR(2)	-0.332895	0.143529	-2.319353	0.0242
AR(6)	-0.035021	0.118670	-0.295111	0.7690
MA(1)	-0.227989	0.108106	-2.108931	0.0396
MA(2)	-0.111656	0.105952	-1.053839	0.2966
MA(7)	0.062224	0.095721	0.650058	0.5184
MA(12)	-0.883228	0.098531	-8.964008	0.0000
R-squared	0.621888	Mean dependent var		0.000820
Adjusted R-squared	0.579876	S.D. dependent var		2.224663
S.E. of regression	1.441960	Akaike info criterion		3.677502

Sum squared resid	112.2794	Schwarz criterion	3.91973
Log likelihood	-105.1638	Durbin-Watson stat	2.12847
3			
5			
Inverted AR Roots	.38 -.29i	.38+.29i	-.14+.64i
			-.14 - .64i
Inverted MA Roots	-.49 -.35i	-.49+.35i	
	1.02	.89 -.49i	.89+.49i
			.51+.85i
	.51 -.85i	.02+.98i	.02 -.98i
			-.49 - .85i
	-.49+.85i	-.84+.49i	-.84 -.49i
			-.99
Estimated MA process is noninvertible			

3.2.3 Estimasi Ulang Kedua

Perhitungan ulang model ARMA dilakukan dengan tidak mengikutsertakan parameter yang tidak signifikan. Model yang selanjutnya diuji adalah model ARMA(2,1(12) Seluruh parameter dari model ARMA(2,1(12)) sudah signifikan, tetapi parameter model MA yang diperoleh tidak invertibel.

3.2.4 Estimasi Ulang Ketiga

Perbaikan model dilakukan dengan mengeluarkan salah satu parameter MA. Diperoleh model yang paling tepat adalah ARMA(2,(12)). Hasil estimasi model ARMA(2,(12)) menunjukkan nilai yang signifikan untuk seluruh parameter.

Model ARMA(2,(12)) yang diperoleh sudah baik untuk digunakan jika tidak ada autokorelasi di dalam residu model tersebut. Uji *Breusch-Godfrey* sampai lag-4 untuk residu model ARMA(2,(12)) memberikan nilai probabilitas 0,018124 yang nilai tersebut lebih kecil dari tingkat signifikansi α 0,05, sehingga hipotesis nul ditolak. Jadi masih terdapat autokorelasi pada residu model ARMA(2,(12)).

Autokorelasi residu juga dapat dilihat melalui nilai ACF dan PACF. Plot ACF dan PACF menunjukkan adanya nilai PACF yang signifikan pada lag-3. Hal tersebut menunjukkan adanya efek AR yaitu pada lag-3 yang harus diikutsertakan ke model.

3.2.5 Estimasi Ulang Keempat

Estimasi model dilakukan lagi dengan memasukkan parameter AR untuk lag-3. Model yang diestimasi adalah model ARMA(3,(12)). Hasil uji dapat dilihat pada Tabel 5. Parameter model ARMA(3,(12)) semuanya sudah signifikan, stasioner dan invertibel. Model ARMA(3,(12)) yang diperoleh dapat ditulis sebagai

$$W_t = -0,651029 W_{t-1} - 0,552192 W_{t-2} - 0,277124 W_{t-3} - 0,915554 e_{t-12} + e_t \quad (1)$$

Tabel 5 Estimasi model ARMA(3,(12))

Dependent Variable: SER09
Method: Least Squares
Date: 12/03/08 Time: 07:43
Sample(adjusted): 4 67
Included observations: 64 after adjusting endpoints
Convergence achieved after 18 iterations
Backcast: -8 3

Variable	Coefficien	Std. Error	t-Statistic	Prob.
	t			
AR(1)	-0.651029	0.125974	-5.167951	0.0000
AR(2)	-0.552192	0.133486	-4.136713	0.0001
AR(3)	-0.277124	0.124447	-2.226839	0.0297
MA(12)	-0.915554	0.055607	-16.46470	0.0000
R-squared	0.675173	Mean dependent var	0.01187	

Adjusted R-squared	0.658931	S.D. dependent var	2.17570	5
S.E. of regression	1.270636	Akaike info criterion	3.37737	6
Sum squared resid	96.87091	Schwarz criterion	3.51230	3
Log likelihood	-104.0759	Durbin-Watson stat	2.03632	3
<hr/>				
Inverted AR Roots	-.05 -.70i	-.05+.70i	-.56	
Inverted MA Roots	.99	.86+.50i	.86 -.50i	
				.50+.86i
	.50 -.86i	.00+.99i	-.00 -.99i	-
				.50+.86i
	-.50 -.86i	-.86+.50i	-.86 -.50i	-.99

3.3 Pemeriksaan Diagnostik Model ARMA (3,(12))

3.3.1 Uji Autokorelasi Residu Model ARMA (3,(12))

Model ARMA(3,(12)) yang diperoleh sudah baik untuk digunakan jika tidak ada autokorelasi di dalam residu model tersebut. Uji *Breusch-Godfrey* sampai dengan lag-7 memberikan nilai probabilitas sebesar 0,244445 yang lebih besar dari tingkat signifikansi α 0,05, sehingga hipotesis nul tidak ditolak. Jadi sudah tidak ada autokorelasi di dalam residu model ARMA(3,(12)). Uji *Breusch-Godfrey* dapat dilihat pada tabel di bawah.

Tabel 6 Uji *Breusch-Godfrey* residu model ARMA(3,(12))

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	1.257624	Probability	0.28910
Obs*R-squared	9.115846	Probability	0.24444

Test Equation:
 Dependent Variable: RESID
 Method: Least Squares
 Date: 12/03/08 Time: 09:01
 Presample missing value lagged residuals set to zero.

Variable	Coefficien	Std. Error	t-Statistic	Prob.
AR(1)	-0.561133	2.119676	-0.264726	0.7922
AR(2)	-0.785525	1.234481	-0.636320	0.5273
AR(3)	0.149458	0.956161	0.156310	0.8764
MA(12)	0.005366	0.058364	0.091934	0.9271
RESID(-1)	0.439859	2.119454	0.207534	0.8364
RESID(-2)	0.282478	1.003647	0.281452	0.7795
RESID(-3)	-0.945877	0.753312	-1.255625	0.2148
RESID(-4)	-0.165970	0.528851	-0.313832	0.7549
RESID(-5)	0.024267	0.400536	0.060587	0.9519
RESID(-6)	-0.114136	0.248575	-0.459162	0.6480
RESID(-7)	-0.117187	0.216260	-0.541879	0.5902
R-squared	0.142435	Mean dependent var	-	0.00337
Adjusted R-squared	-0.019370	S.D. dependent var	1.24000	0

S.E. of regression	1.251960	Akaike info criterion	3.44245
Sum squared resid	83.07247	Schwarz criterion	3.81351
Log likelihood	-99.15863	Durbin-Watson stat	2.00115

3.4 Uji Efek Heteroskedastisitas (ARCH/GARCH)

Indikasi efek heteroskedastisitas dalam residu model ARMA(3,(12)) perlu untuk diuji lebih lanjut. Adanya efek heteroskedastisitas juga dapat diperiksa melalui uji efek ARCH menggunakan uji *Lagrange Multiplier*. Uji dilakukan pada residu model ARMA(3,(12)) sampai dengan lag-7 untuk melihat apakah ada efek ARCH sampai dengan lag tersebut. Uji hipotesis dari uji *Lagrange Multiplier* ARCH sampai lag-7 adalah

$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_7 = 0$ (tidak ada efek ARCH sampai lag-7).

H_1 : paling sedikit terdapat satu $\alpha_k \neq 0$, $k = 1, 2, 3, 4, 5, 6, 7$ (terdapat efek ARCH, paling tidak pada sebuah lag).

Hasil output uji *Lagrange Multiplier* ARCH dapat dilihat pada Tabel 7. Statistik uji *Lagrange Multiplier* sampai lag-7 menghasilkan nilai probabilitas 0,999387 yang lebih besar dari tingkat signifikansi $\alpha = 0,05$, yang berakibat H_0 tidak ditolak. Jadi dapat disimpulkan bahwa di dalam residu model ARMA(3,(12)) tidak terdapat efek ARCH.

Tabel 7 Uji *Lagrange Multiplier* ARCH sampai lag-7 untuk residu model ARMA(3,(12))

ARCH Test:				
F-statistic	0.063924	Probability	0.999556	
Obs*R-squared	0.515811	Probability	0.999387	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 12/08/08 Time: 14:21				
Sample(adjusted): 11 67				
Included observations: 57 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.489789	1.311857	1.135633	0.2616
RESID^2(-1)	0.052162	0.142851	0.365146	0.7166
RESID^2(-2)	0.051026	0.142979	0.356876	0.7227
RESID^2(-3)	0.026592	0.143127	0.185793	0.8534
RESID^2(-4)	0.027790	0.143121	0.194174	0.8468
RESID^2(-5)	-0.023301	0.143137	-0.162788	0.8714
RESID^2(-6)	-0.034182	0.143008	-0.239020	0.8121
RESID^2(-7)	0.007891	0.142900	0.055218	0.9562
R-squared	0.009049	Mean dependent var	1.670136	
Adjusted R-squared	-0.132515	S.D. dependent var	8.365334	
S.E. of regression	8.902363	Akaike info criterion	7.339981	
Sum squared resid	3883.351	Schwarz criterion	7.626725	
Log likelihood	-201.1895	F-statistic	0.063924	
Durbin-Watson stat	1.999571	Prob(F-statistic)	0.999556	

3.5 Peramalan

Ramalan inflasi dengan perbedaan kedua dihitung berdasarkan persamaan (1). Persamaan ramalan model ARMA(3,(12)) untuk satu langkah ke depan adalah

$$\hat{W}_t(1) = -0,651029 W_t - 0,552192 W_{t-1} - 0,277124 W_{t-2} - 0,915554 e_{t-11}. \quad (2)$$

Ramalan untuk k langkah ke depan menjadi

$$\hat{W}_t(k) = -0,651029 W_{t+k-1} - 0,552192 W_{t+k-2} - 0,277124 W_{t+k-3} - 0,915554 e_{t+k-12} \quad (3)$$

dengan $e_{t+1} = W_{t+1} - \hat{W}_t(1)$. Jika $k > 12$, maka ramalan menjadi

$$\hat{W}_t(k) = -0,651029 W_{t+k-1} - 0,552192 W_{t+k-2} - 0,277124 W_{t+k-3}. \quad (4)$$

Hasil ramalan inflasi dengan pembedaan kedua dapat dilihat pada Tabel 15.

Karena pembedaan kedua dirumuskan sebagai

$$W_t = (1 - B)^2 Z_t = Z_t - 2 Z_{t-1} + Z_{t-2},$$

maka nilai data pada saat t dapat dirumuskan sebagai

$$Z_t = W_t + 2 Z_{t-1} - Z_{t-2}. \quad (5)$$

Ramalan nilai inflasi dapat diperoleh menggunakan persamaan (5) yang berdasarkan pada ramalan nilai inflasi dengan pembedaan kedua. Ramalan nilai inflasi untuk 12 periode ke depan dapat

dihitung berturut-turut mulai periode 68 sampai 79 adalah sebagai $\hat{W}_{67}(1)$, $\hat{W}_{67}(2)$, ..., $\hat{W}_{67}(12)$ dengan nilai ramalan 1,0833, -0,3103, ..., -0,2200.

Nilai ramalan inflasi (%) untuk Oktober 2008 sampai September 2009 berturut-turut 13,5133, 14,5762, ..., 16,6859.

KESIMPULAN DAN SARAN

Kesimpulan

Model runtun waktu yang sesuai digunakan untuk memodelkan data inflasi adalah model ARMA(3,(12)) dengan sebelumnya dilakukan pembedaan kedua pada data inflasi. Model tersebut dapat dikatakan sebagai model ARIMA(3,2,(12)) untuk data inflasi asli. Hasil peramalan nilai inflasi untuk 12 periode ke depan menyatakan bahwa nilai inflasi kemungkinan akan mengalami kenaikan.

Saran

Autokorelasi pada lag-12 sangat signifikan di dalam data inflasi dan efeknya masih terlihat walau telah dilakukan pembedaan (*differencing*) dari data sampai dua kali. Hal tersebut dapat diteliti lebih lanjut dengan melihat kemungkinan adanya pola musiman pada data runtun waktu inflasi.

DAFTAR PUSTAKA.

- Agung Ariyanto dan Isnandar Slamet. 2009. Pemodelan dan Simulasi PAD Kabupaten Purworejo di Bidang Retribusi Bus pada Terminal Bus Purworejo, diterima untuk diterbitkan di *Jurnal MathInfo*, Jurusan Matematika FMIPA UNS.
- Bollerslev, Tim. 1986. Generalized Autoregressive Conditional Heteroscedasticity. *Journal of Econometrics*. No.31, 307-28.
- Engle, R. 1982. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Journal of Econometrica*, No. 50, 987-1008.
- Enders. W. 1995. Applied Econometric Time Series, John Wiley and Sons
- Rockinger, M. 2001. A Time-varying Parameter Model to Test for Predictability and Integration in the Stock Markets of Transition Economics, *JASA*, 19, 73-84
- Subanar. 2001. Model ARCH, GARCH dan Model Runtun Waktu Semiparametrik, Seminar Nasional Statistik V, ITS Surabaya.
- Tsay, R. S. 2002. *Analysis of Financial Time Series*. John Wiley & Sons, Inc. Chicago.
- Wahyu Dewi Widyanti dan Isnandar Slamet . 2009. Pemodelan ARCH dan GARCH pada Nilai Tukar Euro terhadap Rupiah, diterima untuk diterbitkan di *Jurnal MathInfo*, Jurusan Matematika FMIPA UNS.