ISBN: 978-602-72658-1-3

Penerapan Model *Neuro*-Garch Pada Peramalan (Studi Kasus: *Return* Indeks Harga Saham Gabungan)
Application Of Neuro-Garch Model On Forecasting (Case Study: Return Composite Stock Price Index)

Hardianty[1], Wenny Kristina[2], Sri Wahyuningsih[2,*]
[1]Laboratorium Ekonomi dan Bisnis Program Studi Statistika FMIPA Universitas Mulawarman
[2]Program Studi Statistika FMIPA Universitas Mulawarman
**Corresponding Author*: swahyuningsih@gmail.com

Abstrak *Salah satu masalah yang dihadapi dalam proses peramalan adalah masalah heteroskedastisitas. Heteroskedastisitas banyak terjadi terutama pada data keuangan. Model Generalized Autoregressive Conditional Heteroskedasticity (GARCH) dan jaringan saraf tiruan model Backpropagation merupakan metode yang dapat digunakan pada data yang mengalami heteroskedastisitas. Dalam penelitian ini, kedua model tersebut dikombinasikan menjadi sebuah model yang disebut Neuro-GARCH. Peramalan dilakukan pada data Return Indeks Harga Saham Gabungan bulan November-Desember 2014 dengan menggunakan data bulan Januari-Oktober 2014. Berdasarkan model Neuro-GARCH tersebut hasil peramalan Return Indeks Harga Saham Gabungan selama 2 bulan mengalami fluktuasi di mana return tertinggi pada tanggal 18 Desember 2014, yaitu sebesar 0,0073 dan terendah pada tanggal 16 Desember 2014, yaitu sebesar -0,0113.*

Kata-kata kunci: ARIMA, heteroskedastisitas, *neuro*-GARCH, *backpropagation*

Pendahuluan

Sebagian besar data *time series* ekonomi dan *financial* seperti pergerakan Indeks Harga Konsumen (IHK), inflasi, indeks harga saham, kurs valuta asing, dan sebagainya merupakan data deret waktu yang tidak stasioner terhadap rata-rata dan ragam/heteroskedastisitas (Aswi dan Sukarna, 2006). Salah satu model *time series* yang dapat digunakan untuk data yang bersifat heteroskedastisitas adalah *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) (Widarjono, 2007).

Selain model tersebut, model yang sering digunakan dalam peramalan adalah jaringan saraf tiruan model *Backpropagation*. Model ini dikenal sebagai model yang sangat baik dalam peramalan karena hasil peramalan yang diperoleh akurat dan memiliki kesalahan yang relatif kecil. *Backpropagation* adalah salah satu metode dari jaringan saraf tiruan yang dapat diaplikasikan dengan baik dalam bidang peramalan (*forecasting*) (Jong, 2005).

Purnamashidi (2013) menggunakan model *Neuro*-ARCH (kombinasi antara model ARCH dengan jaringan saraf tiruan *Backpropagation*) dan Ramadhani (2013) menggunakan model *Neuro*-GARCH (kombinasi antara model GARCH dengan jaringan saraf tiruan *Backpropagation*). Kedua penelitian tersebut meramalkan data saham beberapa perusahaan dan membandingkannya dengan jaringan saraf tiruan *Backpropagation.*

Dari penelitian tersebut penulis tertarik untuk menerapkan teknik gabungan antara jaringan saraf tiruan dengan model GARCH yang selanjutnya disebut dengan *Neuro-GARCH* dalam meramalkan nilai *Return* Indeks Harga Saham Gabungan.

Tujuan penelitian ini adalah mengetahui bentuk arsitektur jaringan model terbaik dari *Neuro*-GARCH dalam meramalkan RIHSG dan mengetahui perbandingan hasil peramalan dengan data aktual RIHSG pada bulan November-Desember 2014 dengan menggunakan model *Neuro*- GARCH.

Metode Penelitian

Adapun langkah-langkah yang dilakukan dalam peramalan data RIHSG dengan model *Neuro*-GARCH adalah sebagai berikut:

1. Peramalan dengan menggunakan model GARCH :
   a. Input data saham
   b. Plot data saham
   c. Identifikasi kestasioneran data (ragam dan rata-rata).
   d. Identifikasi model dengan melihat Plot *Autocorrelation Function* (ACF) dan Plot *Partial Autocorrelation Function* (PACF).
   e. Membentuk persamaan autoregresi sebagai model awal.

ISBN: 978-602-72658-1-3

f. Pengujian heteroskedatisitas atau efek ARCH/GARCH pada residual.
g. Estimasi parameter model GARCH.
h. Uji kelayakan model.

2. Peramalan kembali data hasil peramalan model GARCH dengan menggunakan model *backpropagation.*
   a. Menetapkan tujuan sistem.
   b. Menentukan fungsi aktivasi.
   c. Membentuk input jaringan dengan kuadrat sisaan model GARCH (1,1).
   d. Pembagian komposisi data (83% data *training* dan 17% data *testing*).
   e. Inisialisasi jaringan dengan menentukan arsitektur jaringan.
   f. Proses pelatihan jaringan.
   g. Simulasi dan pengujian, simulasi dilakukan terhadap matrik *input* data 83% dan sedangkan pengujian dilakukan terhadap matrik *input* data 17%.
   h. Pemilihan arsitektur jaringan yang optimum sehingga siap digunakan dalam peramalan.

Hasil dan Pembahasan

Pemodelan GARCH (1,1)

Langkah pertama adalah memodelkan data RIHSG ke dalam model ARIMA dengan hasil sebagai berikut :

$$Z_t = 0{,}9988 Z_{t-1} + a_t \qquad (1)$$

dilanjutkan ke model GARCH sebagai berikut.

1. Efek ARCH/GARCH

Setelah memperoleh model terbaik maka langkah selanjutnya adalah melihat apakah terdapat efek ARCH/GARCH atau heteroskedastisitas pada kuadrat residual model tersebut dengan menggunakan uji ARCH-LM sebagai berikut:

Tabel 1. Uji Efek ARCH

Lag	Obs*R-squared	α
1	0,0000	5%
2	0,0000	5%
3	0,0000	5%
4	0,0001	5%
5	0,0001	5%

Berdasarkan tabel 1 nilai probabilitas dari *Obs*R-squared* lebih kecil dari $\alpha = 5\%$ maka dapat diputuskan untuk menolak H_0 atau data bersifat heteroskedastisitas (terdapat efek ARCH/GARCH) pada model. Dengan demikian model GARCH dapat langsung digunakan tanpa menghilangkan heteroskedastisitas pada model.

2. Identifikasi Model GARCH

Prosedur analisis GARCH terhadap data menggunakan *EViews* serupa dengan ARCH. Perbedaannya hanyalah nilai order GARCH menjadi lebih dari 0. Untuk analisis awal biasanya dipilih GARCH dengan ordo $p = 1$ dan $q = 1$ atau GARCH (1,1). Tahapan berikutnya adalah memeriksa apakah terdapat komponen baik p maupun q dengan ordo lebih tinggi yang juga signifikan melalui proses *overfitting*. Dengan kata lain, proses *overfitting* ini adalah melakukan analisis ulang terhadap data dengan menggunakan ordo *p* maupun *q* yang lebih tinggi dari *p* dan *q* yang sudah dicobakan. Ordo *p* dan *q* yang dicobakan biasanya tidak melebihi 4. Pada tabel di bawah disajikan model hasil *overfitting* untuk tiga pasangan ordo (*p,q*) lain, yaitu GARCH (1,1), GARCH (1,2), GARCH (2,1) dan GARCH (2,2).

3. Pendugaan Parameter

Tabel 2. Uji Signifikansi Model GARCH

Model	Parameter	*P-value*	Signifikan
GARCH (1,1)	α_0	0,0002	Ya
	β_1	0,0007	Ya
	α_1	0,0000	Ya
GARCH (1,2)	α_0	0,4385	Tidak
	β_1	0,4249	Tidak
	α_1	0,3691	Tidak
	α_2	0,9600	Tidak
GARCH (2,1)	α_0	0,0006	Ya
	β_1	0,3310	Tidak
	β_2	0,9597	Tidak
	α_1	0,0000	Ya
GARCH (2,2)	α_0	0,2676	Tidak
	β_1	0,0024	Ya
	β_2	0,5820	Tidak
	α_1	0,8603	Tidak

Berdasarkan pengujian signifikansi parameter pada Tabel 2, dapat diperoleh kesimpulan bahwa model parameter yang signifikan berbeda dengan nol untuk data

ISBN: 978-602-72658-1-3

RIHSG adalah GARCH (1,1), sedangkan yang signifikan sama dengan nol adalah GARCH (1,2), GARCH (2,1) dan GARCH (2,2).

4. Uji Kelayakan Model

Setelah memperoleh parameter persamaan GARCH (1,1) akan dilakukan pengujian kelayakan model tersebut untuk melihat efek ARCH, dan normalitas pada residual.

Tabel 3. Kenormalan Residual

Model	*P-value*	α	Normal
GARCH(1,1)	0,1448	5%	Ya

Selanjutnya adalah melihat apakah terdapat efek ARCH/GARCH atau heteroskedastisitas pada model.

Tabel 4. Pengujian Efek ARCH/GARCH

Lag	Obs*R-squared	α
1	0,5110	5%
2	0,2811	5%
3	0,4542	5%
4	0,6163	5%
5	0,6061	5%

Dari hasil pengujian sudah memenuhi kelayakan model sehingga model sudah dapat digunakan dalam peramalan.

Disimpulkan bahwa GARCH (1,1) adalah model terbaik sehingga akan digunakan dalam peramalan RIHSG pada penelitian ini. Dengan menggunakan *Maximum Likelihood Method* yang telah tersedia pada program *Eviews*, estimasi parameter model GARCH (1,1) dari model pendahuluan ARIMA (1,0,0) sebagai berikut:

$$Z_t = 0{,}987081 Z_{t-1} + a_t \quad (2)$$

$$\sigma_t^2 = 0{,}0014 - 0{,}0508\sigma_{t-1}^2 + 1{,}0258\varepsilon_{t-1}^2 \quad (3)$$

Pemodelan *Neuro*-GARCH

Berdasarkan data harian RIHSG selama 1 tahun tersebut dibentuk jaringan dengan 2 masukan / *input* dan 1 target. Jumlah *hidden layer* (layar tersembunyi) yang digunakan dalam penelitian ini sebanyak satu lapisan dengan jumlah unit pada setiap data dimulai dari yang terkecil yaitu 5, 10, dan 15 sehingga arsitektur jaringan yang terbentuk adalah sebagai berikut:

Tabel 5. Struktur Arsitektur Jaringan Model *Neuro*-GARCH

Return Indeks Harga Saham Gabungan
2-5-1
2-10-1
2-15-1

Arsitektur yang digunakan pada tabel 5, selanjutnya menggunakan parameter-parameter *input* dalam *training* dan *testing* parameter-parameter tersebut adalah:

Tabel 6. Inisialisasi Parameter Model *Neuro*-GARCH

Parameter	Nilai Uji
Maksimum epochs (iterasi)	5000
MSE *training* dan *testing*	0,01
Learning rate	0,5

Proses *training* akan berhenti ketika MSE jaringan mendekati atau bahkan lebih kecil daripada MSE yang ditentukan, atau jika jumlah *epochs* (iterasi) telah mencapai batas maksimal dari iterasi yang ditentukan.

Pola *Training* dan *Testing*

Data hasil peramalan dengan model GARCH dibagi menjadi 83% data *training* dan 17% data *testing*. Terdapat 244 data harian dari Januari 2014-Desember 2014, sehingga data *training* 83% dari 244 = 203 hari (203 data dari tanggal 2 Januari 2014-31 Desember 2015) dan 17% sisanya = 41 hari (41 data dari tanggal 3 November 2014-31 Desember 2014) adalah data *testing*

Pemilihan Model Terbaik

Tabel 7. MSE Hasil *Training* dan *Testing* data RIHSG

Jumlah Unit Lapisan	MSE	
	Training	Testing
2-5-1	0,111403	0,036769
2-10-1	0,085450	0,009997
2-15-1	0,014874	0,009991

Pemilihan model terbaik didasarkan dari nilai MSE yang dihasilkan model, semakin kecil nilai MSE maka semakin baik model tersebut. Berdasarkan Tabel 7, maka model terbaik yaitu model dengan jaringan unit lapisan 2-15-1 dengan MSE *testing* sebesar 0,009991.

ISBN: 978-602-72658-1-3

Analisis Data *Training* dan *Testing* Model 2-15-1

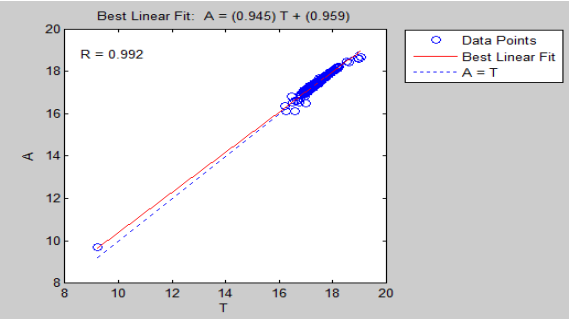

Gambar 1. Grafik hasil data *training*

Gradien garis terbaik (*m1*) = 0,945
Konstanta (*a1*) = 0,959
Koefisien Korelasi (*r1*) = 0,992

Koefisien korelasi bernilai 0,992 dan mendekati 1, menunjukkan hasil yang baik untuk kecocokan *output* jaringan dengan target.

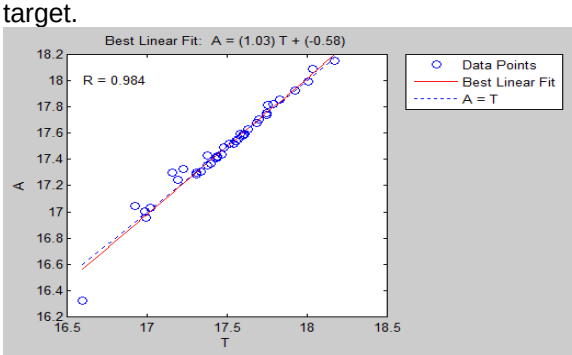

Gambar 2. Grafik hasil data *testing*

Gradien garis terbaik (*m2*) = 1,033
Konstanta (*a2*) = -0,578
Koefisien Korelasi (*r2*) = 0,984

Koefisien korelasi bernilai 0,984 dan mendekati 1, menunjukkan hasil yang baik untuk kecocokan *output* jaringan dengan target. Dibandingkan dengan hasil pelatihan nilai korelasi pengujian lebih kecil dari data pelatihan.

Peramalan dengan *Neuro*-GARCH

Berdasarkan model yang terbentuk pada Tabel 7, maka langkah selanjutnya adalah melakukan peramalan beberapa periode pada data RIHSG. Berikut adalah hasil ramalan dari data RIHSG:

Tabel 8. Ramalan data RIHSG tahun 2014

Hari	Ramalan $\left(\frac{1}{Z_t}\right)$
1	8,7278
2	8,6682
3	8,7157
4	8,6087
5	8,5999
⋮	⋮
39	0,8396
40	9,1288
41	8,7628

Hasil *output* ramalan 41 hari tersebut masih berbentuk Z_t yang kemudian untuk menghasilkan data asli harus dikembalikan ke data awal dengan menggunakan rumus:

$$\hat{Z}_t = \frac{1}{Z_t} \text{ dan } Z_t = (0{,}014 + 0{,}1) - \hat{Z}_t \qquad (4)$$

Setelah dilakukan pengembalian data, hasil ramalan adalah sebagai berikut:

Tabel 9. Hasil peramalan menggunakan Model *Neuro-GARCH*

Hari	Ramalan	Aktual
1	-0,0005	-0,000345
2	-0,0013	-0,001246
3	-0,0007	-0,000352
4	-0,0021	-0,002803
5	-0,0022	-0,004057
⋮	⋮	⋮
39	0,0008	0,0009563
40	0,0044	0,0040547
41	-0,0001	0

Selanjutnya, dari hasil ramalan juga diperoleh perbandingan grafik data aktual dan data ramalan, seperti ditampilkan pada Gambar 3.

ISBN: 978-602-72658-1-3

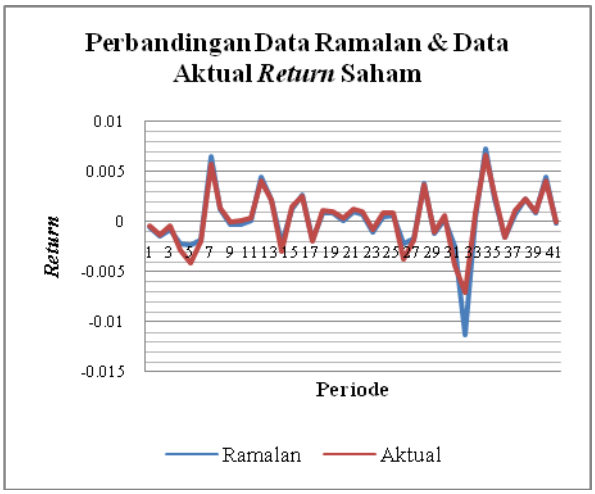

Gambar 3. Perbandingan data aktual dan data ramalan RIHSG tahun 2014

Berdasarkan Gambar 3, diketahui bahwa data hasil ramalan dan data aktual hampir berhimpit, yang mengindikasikan bahwa hasil ramalan tersebut cukup baik. Hasil ramalan selama 41 hari pada grafik di atas, diketahui bahwa data hasil peramalan mengalami fluktuasi. Dapat dilihat pada grafik hasil ramalan dari model *Neuro*-GARCH, RIHSG tertinggi terjadi pada hari ke- 34 yaitu pada tanggal 18 Desember 2014 sebesar 0,0073 dan terendah pada hari ke- 32 yaitu pada tanggal 16 Desember 2014 sebesar -0,0113,

Kesimpulan

Dari hasil penelitian, pembahasan, dan analisis data maka diperoleh kesimpulan sebagai berikut:

1. Bentuk arsitektur jaringan model terbaik *Neuro*-GARCH untuk peramalan RIHSG adalah model dengan jaringan unit lapisan (2-15-1) dengan MSE *training* sebesar 0,014874 dan *testing* sebesar 0,009991.
2. Dari hasil peramalan pada bulan November-Desember 2014 dengan menggunakan model *Neuro*-GARCH dapat dilihat bahwa RIHSG tertinggi terjadi pada tanggal 18 Desember 2014, yaitu sebesar 0.0073 dan terendah pada tanggal 16 Desember 2014, yaitu sebesar -0.0113.

Daftar Pustaka

[1] Aswi dan Sukarna. 2006. *Analisis Deret Waktu.* Makassar: Andira Publisher.

[2] Widarjono, Agus. 2007. *Ekonometrika : Teori dan Aplikasi untuk Ekonomi dan Bisnis.* Yogyakarta : Penerbit Ekonosia UII.

[3] Jong Jek Siang. 2005. *Jaringan Syaraf Tiruan dan Pemprogramannya Menggunakan MATLAB.* Yogyakarta: Andi Offset.

[4] Purnamasidhi, Wahyu. 2013. *Pemodelan Jaringan Syaraf Tiruan dengan Peubah Input Model ARCH pada Data Return Saham untuk Peramalan Volatilitas. Jurnal Mahasiswa Statistik.* Vol.1 No.1. Hal 61-65. Malang: Universitas Brawijaya

[5] Ramadhani, Theta R. 2013. *Penerapan Model Neuro-GARCH untuk Peramalan Data Saham*. *Jurnal Mahasiswa Statistik*. Vol.1 No.1. Hal 1-4. Malang: Universitas Brawijaya.