

**PREDIKSI VOLATILITAS SAHAM PERUSAHAAN PERTAMBANGAN BATU BARA
DENGAN METODE ARTIFICIAL NEURAL NETWORKS - GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY**

**FORECASTING VOLATILITY OF COAL MINING COMPANY STOCK WITH
ARTIFICIAL NEURAL NETWORKS - GENERALIZED AUTOREGRESSIVE
CONDITIONAL HETEROSCEDASTICITY METHOD**

I Wayan Bagus Satriawan

Program Studi Ilmu Komputasi, Fakultas Informatika, Universitas Telkom
iwayanbagus.satriawan@gmail.com

Abstrak

Saham adalah salah satu jenis surat berharga yang digunakan sebagai tanda penyerta modal seseorang atau badan usaha dalam suatu perusahaan. Sebelum berinvestasi, penting bagi investor untuk mengetahui seberapa besar risiko dan *return* dari saham tersebut. Volatilitas adalah sebuah metode statistik untuk mengukur fluktuasi harga saham dalam periode tertentu. Salah satu model *time-series* terbaik dalam memprediksi volatilitas harga saham adalah *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Pengoptimasian metode dilakukan untuk meningkatkan prediksi volatilitas. Metode yang digunakan untuk mengoptimasi model GARCH adalah model *Artificial Neural Networks* (ANN). Pada Tugas Akhir ini menentukan akurasi model digunakan metode RMSE dan MAE. Berdasarkan hasil analisis model ANN-GARCH lebih baik dibandingkan model GARCH(1,1) dalam akurasi model. Hasil RMSE dan MSE dengan model GARCH adalah RMSE = 2.4867e-06 dan MAE = 7.9885e-08, sedangkan dengan model ANN-GARCH mendapatkan hasil terbaik RMSE = 3.5016e-07 dan MAE = 1.1249e-08.

Kata kunci : Saham, Volatilitas, *Generalized Autoregressive Conditional Heteroscedasticity*, *Artificial Neural Networks*, ANN-GARCH

Abstract

Stock is a type of securities used as a sign of a person's capital or a business entity within a company. Before investing, it is important for investors to know how much risk and return of the stock. Volatility is a statistical method for measuring stock price fluctuations in a given period. One of the best time-series models in predicting stock price volatility is the Generalized Autoregressive Conditional Heteroscedasticity (GARCH). The optimization of methods is done to improve volatility predictions. The method used to optimize the GARCH model is the Artificial Neural Networks (ANN) model. In this Final Project determine the accuracy of the model used RMSE and MAE methods. Based on ANN-GARCH model analysis result better than GARCH model (1,1) in model accuracy. The result of RMSE and MSE with GARCH model is RMSE = 2.4867e-06 and MAE = 7.9885e-08, while with ANN-GARCH model get best result RMSE = 3.5016e-07 and MAE = 1.1249e-08.

Keywords : Stock, Volatility, *Generalized Autoregressive Conditional Heteroscedasticity*, *Artificial Neural Networks*, ANN-GARCH

1. Pendahuluan

Saham-saham pada sektor pertambangan saat ini tengah menjadi sorotan. Setelah tahun lalu mengalami pelemahan, saham-saham pertambangan kali ini bisa menjadi penopang penguatan indeks saham Indonesia yang salah satu faktor penguatnya ialah sentimen perbaikan pada harga batu bara. Hal ini bisa menjadi salah satu pertimbangan bagi investor untuk menginvestasikan uangnya pada sektor pertambangan khususnya batu bara. Tetapi sebelum berinvestasi, penting bagi investor untuk mengetahui seberapa besar risiko dari saham tersebut. Volatilitas dapat mengukur saham yang baik untuk berinvestasi dengan melihat fluktuasi sahamnya tinggi atau rendah. Jika volatilitas saham cenderung tinggi maka perubahan harga sahamnya juga akan semakin tidak stabil atau risikonya besar. Maka dari itu diperlukannya sebuah sistem untuk menganalisa dan memprediksi volatilitas harga saham agar bisa menjadi bahan pertimbangan bagi investor dalam berinvestasi saham.

Volatilitas adalah sebuah metode statistik untuk mengukur fluktuasi harga saham dalam periode tertentu. Dari ukuran tersebut dapat dilihat kenaikan dan penurunan harga saham dalam periode yang pendek dan tidak melihat tingkat harga, namun derajat variasinya dari satu periode ke periode berikutnya [1]. Sudah banyak studi yang mempelajari tentang prediksi volatilitas harga saham. Salah satu metode *time-series* terbaik dalam memprediksi volatilitas harga saham adalah *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). GARCH adalah salah satu model *time-series* heteroskedastik yang dapat mengakomodir perubahan perilaku volatilitas terhadap waktu. GARCH juga memiliki dasar yang baik untuk memahami suatu model yang kompleks dan kerangka yang baik untuk volatilitas secara rasional.

Artificial Neural Networks (ANN) merupakan salah satu pemodelan yang mampu mengoptimasi suatu model dengan meningkatkan keakuratan prediksi. Pada jurnal Werner Kristjanpoller (2016), menggunakan model *Artificial Neural Networks - Generalized Autoregressive Conditional Heteroscedasticity* (ANN-GARCH) untuk meningkatkan akurasi prediksi volatilitas yang cukup signifikan. Oleh karena itu pada tugas akhir ini, penulis menggunakan model ANN-GARCH untuk meningkatkan prediksi volatilitas indeks harga saham pada perusahaan pertambangan batu bara Adaro Energy Tbk.

2. Kajian Pustaka

2.1 Return Saham

Saham adalah salah satu jenis surat berharga yang digunakan sebagai tanda penyerta modal seseorang atau badan usaha dalam suatu perusahaan. Dengan menyertakan modal tersebut maka seorang atau badan usaha pemilik saham berhak memiliki klaim atas pendapatan perusahaan, klaim atas aset perusahaan, dan berhak hadir dalam Rapat Umum Pemegang Saham (RUPS).

Return saham adalah suatu hasil dari investasi saham yang dapat mengakibatkan keuntungan atau kerugian bagi pemodal dengan cara menghitung selisih harga saham periode saat ini dengan periode sebelumnya. Secara umum terdapat dua tipe *return* yaitu *return* sederhana dan *return* majemuk. *Return* sederhana merupakan tipe *return* yang bersifat bebas skala yaitu *return* suatu aset dapat dibandingkan dengan *return* aset lainnya. Sedangkan *return* majemuk merupakan *return* yang bersifat adiktif berarti penjumlahan *return* pada setiap periode dapat menentukan *return* pada suatu periode. Perhitungan nilai *return* sederhana sebagai berikut [2]:

$$X_t = \frac{P_t - P_{t-1}}{P_{t-1}} = \frac{P_t}{P_{t-1}} - 1 \quad (2.1)$$

Return sederhana tidak memiliki sifat aditif. Maka dari itu *return* majemuk digunakan untuk memenuhi sifat aditif tersebut. Perhitungan nilai *return* majemuk sebagai berikut:

$$X_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad (2.2)$$

2.2 Volatilitas

Volatilitas adalah sebuah metode statistik untuk mengukur fluktuasi harga saham dalam periode tertentu. Dari ukuran tersebut dapat dilihat kenaikan dan penurunan harga saham dalam periode yang pendek dan tidak melihat tingkat harga, namun derajat variasinya dari satu periode ke periode berikutnya [6]. Jika volatilitas semakin tinggi, maka kemungkinan fluktuasi harga saham dan risiko yang didapat juga akan semakin tinggi. Volatilitas memiliki kecenderungan sifat untuk dipertimbangkan oleh investor dalam berinvestasi, yaitu jika angka volatilitas cenderung tinggi maka cocok untuk investor yang berinvestasi dalam jangka pendek karena risiko yang dimiliki tinggi, sedangkan jika angka volatilitas rendah maka cocok untuk investor yang ingin berinvestasi dalam jangka panjang karena risiko yang dimiliki rendah. Volatilitas dapat ditulis dengan persamaan:

$$\begin{aligned} \sigma_t^2 &= \text{VAR}(X_t | F_{t-1}) \\ &\approx \frac{1}{(t-1)} \sum_{i=1}^t (X_i - \bar{X}_i)^2 \end{aligned} \quad (2.3)$$

2.3 Generalized Autoregressive Conditional Heteroscedasticity

Generalized Autoregressive Conditional Heteroscedasticity (GARCH) merupakan salah satu model *time-series* yang diperkenalkan oleh Engle (1982) Autoregressive Conditional Heteroscedasticity (ARCH) dan kemudian

dikembangkan oleh Bollerslev pada tahun 1986 menjadi GARCH. Model ini didasari pada asumsi perkiraan variansi yang berbeda-beda tergantung pada variansi terdahulu[3]. Kenaikan atau penurunan *return* yang tak terduga pada waktu t akan menghasilkan keragaman yang diharapkan pada periode berikutnya GARCH dapat mengakomodir perubahan perilaku volatilitas terhadap waktu dan dapat memahami model volatilitas yang kompleks. GARCH juga merupakan model yang baik untuk memodelkan suatu data deret waktu dengan ragam yang tidak stasioner. Model umum GARCH ordo p dan q atau GARCH (p, q) dapat didefinisikan sebagai berikut[4] :

$$\begin{aligned} X_t &= \sigma_t \cdot \varepsilon_t \\ \sigma_t^2 &= \alpha_0 + \sum_{i=1}^q \alpha_i X_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \end{aligned} \quad (2.4)$$


Dengan $p \geq 0$, $q \geq 0$, $\alpha_0 > 0$ dan $\alpha_i \geq 0$ untuk $i = 1, \dots, q$ dan $\beta_j \geq 0$ untuk $j = 1, \dots, p$. Seperti ARCH syarat $\alpha_0 > 0$, $\alpha_i \geq 0$ dan $\beta_j \geq 0$ dibutuhkan agar variansi bersyarat $\sigma_t^2 > 0$. Pada tugas akhir ini menggunakan GARCH (1, 1), model GARCH (1,1) merupakan model GARCH sederhana yang sering digunakan dengan ordo $q = p = 1$ yang digunakan untuk memprediksi volatilitas yang dikaitkan dengan *heteroscedasticity*, model ini didefinisikan dengan persamaan sebagai berikut :

$$\begin{aligned} X_t &= \sigma_t \cdot \varepsilon_t \\ \sigma_t^2 &= \alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \end{aligned} \quad (2.5)$$

2.4 Artificial Neural Networks

Artificial Neural Networks (ANN) adalah suatu arsitektur untuk memodelkan cara kerja sistem syaraf manusia dalam melaksanakan tugas tertentu. ANN merupakan sistem pemrosesan informasi yang di desain untuk melakukan proses belajar melalui perubahan bobot. Sebuah ANN minimal tersusun dari lapisan *input* dan lapisan *output*. Dalam

beberapa tipe jaringan, diantara lapisan *input* dan lapisan *output* terdapat lapisan tersembunyi (*hidden layer*)[6]. Ilustrasi struktur ANN dapat di gambarkan sebagai berikut:



Gambar 2.1 : Ilustrasi dari *Artificial Neural Networks*

Pada gambar ilustrasi diatas merupakan bentuk dari *Multi Layer Perceptron* dengan tiga *inputs variables* (variabel masukan), satu *hidden layer* (lapis tersembunyi) dengan 2 *neuron* dan satu *neuron* pada *output variables* (variabel keluaran). Pemodelan di dalam ANN terbagi menjadi dua yaitu proses *training* dan *testing*. Proses *training* dan *testing* membutuhkan suatu algoritma, pada Tugas Akhir ini menggunakan algoritma *Backpropagation*. Pada algoritma propagasi balik terdapat dua tahap perhitungan, yaitu : 1) Perhitungan maju yang bertujuan untuk menghitung *error* antara keluaran aktual dan target. 2) Perhitungan mundur yang bertujuan untuk mempropagasikan balik *error* tersebut guna memperbaiki bobot-bobot pada semua *neuron* yang ada[5].

- 1) Perhitungan Maju
Perhitungan maju digunakan untuk menghitung keluaran dari *hidden layer* dapat dituliskan :

$$A1 = \frac{1}{1 + e^{-(W1*P+B1)}} \quad (2.6)$$

Hasil dari *hidden layer* akan dipakai untuk menghitung keluaran *output layer* dengan persamaan :

$$A2 = W2 * A1 + B2 \quad (2.7)$$

Selisih antara nilai target dengan keluaran jaringan adalah *error* yang dituliskan sebagai :

$$E = T - A2 \quad (2.8)$$

Setelah menghitung *error* selanjutnya mencari *Mean Square Error* dinyatakan dengan persamaan :

$$MSE = \frac{\sum E^2}{N} \quad (2.9)$$

- 2) Perhitungan Mundur

Dari MSE yang diperoleh akan dipakai sebagai parameter dalam pelatihan. Nilai *error* akan digunakan pada propagasi balik untuk memperbaiki bobot-bobot sinaptik dari semua *neuron* pada *hidden layer* dan *output layer*. Pada perbaikan bobot diberikan persamaan-persamaan berikut :

$$\begin{aligned} D2 &= (1 - A2^2) * E \\ D1 &= (1 - A1^2) * (W2 * D2) \\ dW1 &= lr * D1 * P \\ dB1 &= lr * D1 \\ dW2 &= lr * D2 * P \\ dB2 &= lr * D2 \end{aligned} \quad (2.10)$$

Setelah mendapat nilai yang sesuai dengan kontribusi *error* keluaran, bobot-bobot jaringan diperbaiki dengan *error* yang diperkecil, dengan persamaan :

$$\begin{aligned} W1 &= W1 + dW1 \\ B1 &= B1 + dB1 \\ W2 &= W2 + dW2 \\ B2 &= B2 + dB2 \end{aligned} \quad (2.11)$$

Langkah diatas akan terus di ulang hingga nilai MSE yang telah ditentukan tercapai.

2.5 Validasi Model

Pada validasi model ini menggunakan metode *Root Mean Squad Error (RMSE)* *Mean Absolute Error (MAE)*.

2.5.1 Root Mean Squat Error

Root Mean Squat Error (RMSE) adalah standar deviasi dari residual, residual merupakan ukuran selisih antara nilai perkiraan dengan nilai pengamatan. RMSE sering digunakan untuk mengukur tingkat akurasi model, *forecasting*, dan *regression analysis* untuk memverifikasi hasil eksperimen[8]. RMSE didefinisikan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (X_t - \hat{X}_t)^2}{n}} \quad (2.12)$$

Nilai prediksi yang digunakan sebagai inputan untuk menghitung RMSE, ada hubungan langsung dengan koefisien korelasi. Jika koefisien korelasi = 1, maka RMSE = 0 karena semua titik terletak pada garis[8].

2.5.2 Mean Absolute Error


Mean Absolute Error (MAE) adalah kuantitas yang digunakan untuk mengukur nilai *error* dari hasil prediksi dengan nilai sebenarnya. MAE didefinisikan sebagai berikut:

$$MAE = \frac{\sum_{i=1}^n |X_i - \hat{X}_i|}{n} \quad (2.13)$$

MAE menggunakan skalayang sama dengan data yang diukur. Hal ini dikenal sebagai ukuran akurasi skala, yang mana X_i adalah nilai data asli dan \hat{X}_i adalah nilai prediksi.

3. Analisis Perancangan Sistem

3.1 Data

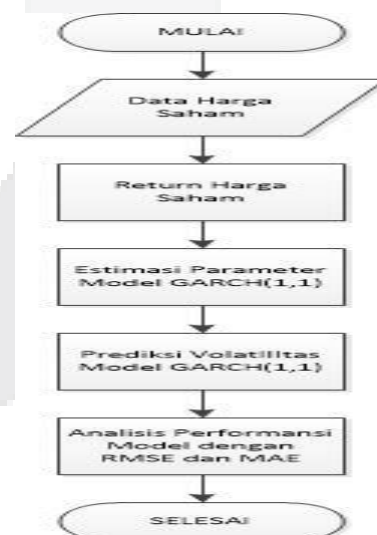


Gambar 3.1 Grafik Close Price Adaro Energy Tbk.

Data dalam Tugas Akhir ini menggunakan data saham Adaro Energy Tbk. yang diambil dari Yahoo Finance. Data yang digunakan yaitu data historis harian *close price* saham selama periode empat tahun dari tanggal 1 Oktober 2012 sampai dengan 30 September 2016. Jumlah data historis harian yang tersedia pada rentang waktu tersebut adalah 969 data.

3.2 Alur Perancangan Sistem


3.2.1 Alur Perancangan Sistem GARCH(1,1)



1. Memasukkan data harian *Close Price* saham Adaro Energy Tbk.,
2. Menentukan nilai *return* majemuk dari data harian *Close Price* saham menggunakan formula (2.2),
3. Menentukan estimasi parameter model GARCH(1,1) dari data harian *Close Price* saham dengan menggunakan metode *maximum likelihood estimation* (MLE),
4. Menentukan prediksi nilai volatilitas berdasarkan estimasi parameter model GARCH(1,1),

- Validasi dari hasil prediksi nilai volatilitas menggunakan metode *Root Mean Absolute Error* (RMSE) dan *Mean Absolute Error* (MAE) untuk mengevaluasi model peramalan.

3.2.2 Alur Perancangan Sistem ANN-GARCH(1,1)




- Memasukkan data harian *Close Price* saham Adaro Energy Tbk.,
- Menentukan nilai *return* majemuk dari data harian *Close Price* saham menggunakan formula (2.2),
- Menentukan estimasi parameter model GARCH(1,1) dari data harian *Close Price* saham dengan menggunakan metode *maximum likelihood estimation* (MLE),
- Menentukan prediksi nilai volatilitas berdasarkan estimasi parameter model GARCH(1,1),
- Menentukan prediksi nilai volatilitas menggunakan model ANN-GARCH(1,1) dari hasil prediksi dengan model GARCH(1,1),
- Validasi dari hasil prediksi nilai volatilitas menggunakan metode *Root Mean Absolute Error* (RMSE) dan *Mean Absolute Error*

(MAE) untuk mengevaluasi model peramalan.

4. Analisis Implementasi Hasil

4.1 Analisis Data



Gambar 4.1 Grafik Analisis Data Saham Adaro Energy Tbk.

Pada Gambar 4.1 menunjukkan grafik harga saham Adaro Energy Tbk. periode 1 September 2012 sampai 31 Oktober 2016 dan grafik volatilitas saham Adaro Energy Tbk. pada gambar tersebut dapat dilihat penurunan harga saham pada data ke-100 sampai 200, dan juga dapat data ke-500 sampai 700. Akan tetapi mulai mengalami penguatan pada data ke-800 sampai 969. Ketika harga saham mengalami penurunan maka volatilitas mengalami kenaikan dan sebaliknya ketika harga saham mengalami kenaikan maka volatilitas mengalami penurunan.

4.2 Model GARCH(1,1)

4.2.1 Sifat Distribusi Model GARCH(1,1)

Ekpektasi Bersyarat

Berdasarkan pembahasan pada kajian pustaka mengenai model *Markov Regime Switching* GARCH(1,1) pada formula (2.8) maka:

$$\begin{aligned}
 E(X_t|X_{t-1}) &= E(\sigma_t \cdot \varepsilon_t|X_{t-1}) \\
 &= E(\sigma_t|X_{t-1}) \cdot E(\varepsilon_t|X_{t-1})
 \end{aligned}$$

$$\begin{aligned}
 &= E \left(\left(\sqrt{\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2} \right) | X_{t-1} \right) \cdot E(\varepsilon_t) \\
 &= E \left(\left(\sqrt{\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2} \right) | X_{t-1} \right) \cdot 0 \\
 &= 0
 \end{aligned}$$

Variansi Bersyarat

$$\begin{aligned}
 Var(X_t | X_{t-1}) &= E(X_t^2 | X_{t-1}) - (E(X_t | X_{t-1}))^2 \\
 &= E(\sigma_t^2 \cdot \varepsilon_t^2 | X_{t-1}) \\
 &= E(\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2 | X_{t-1}) \cdot E(\varepsilon_t^2 | X_{t-1}) \\
 &= \alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \\
 &= \sigma_t^2
 \end{aligned}$$

4.2.2 Fungsi Likelihood Model GARCH(1,1)

Berdasarkan perhitungan ekspektasi dan variansi bersyarat model GARCH(1,1). Dengan $\varepsilon_t \sim N(0,1)$, maka $X_t | X_{t-1} \sim N(0, \alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2)$, sehingga fungsi dari GARCH(1,1) :

$$\begin{aligned}
 f_{X_t | X_{t-1}}(x_t | x_{t-1}) &= \frac{1}{\sqrt{2\pi \cdot \sigma_t^2}} \exp \left(-\frac{1}{2} \cdot \frac{(x_t - \mu_t)^2}{\sigma_t^2} \right) \\
 &= \frac{1}{\sqrt{2\pi \cdot (\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2)}} \exp \left(-\frac{1}{2} \cdot \frac{x_t^2}{(\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2)} \right) \quad (4.1)
 \end{aligned}$$

Untuk mendapatkan nilai penaksiran dari parameter $\alpha_0, \alpha_1, \beta_1$, digunakan metode *Maksimum Likelihood*, dengan fungsi *likelihood*nya adalah :

$$\begin{aligned}
 L(\alpha_0, \alpha_1, \beta_1 | (X_t | X_{t-1})) &= \\
 &= \prod_{t=2}^n \frac{1}{\sqrt{2\pi \cdot (\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2)}} \exp \left(-\frac{1}{2} \cdot \frac{x_t^2}{(\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2)} \right) \\
 l(\theta) &= \log(L(\alpha_0, \alpha_1, \beta_1 | (X_t | X_{t-1}))) \\
 &= -\frac{1}{2} \sum_{t=2}^n \left(\log(2\pi) + \log(\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2) + \frac{x_t^2}{(\alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 \sigma_{t-1}^2)} \right) \quad (4.2)
 \end{aligned}$$

4.2.3 Nilai Parameter Likelihood GARCH(1,1)

Berdasarkan metode *Maksimum Likelihood* diperoleh nilai parameter α_0, α_1 dan β_1 . Berikut parameter yang di hasilkan :


α_0	α_1	β_1
$1.88188 \cdot 10^{-4}$	0.213095	0.801137

Tabel 4.1 Parameter GARCH(1,1)

Setelah diperoleh parameter dari hasil metode *Maksimum Likelihood*, selanjutnya dilakukan prediksi nilai volatilitas dengan menggunakan model GARCH(1,1) dari parameter yang telah diperoleh. Definisi model sebagai berikut :

$$\begin{aligned}
 X_t &= \sigma_t \cdot \varepsilon_t \\
 \sigma_t^2 &= 1.88188 \cdot 10^{-4} + 0.213095 X_{t-1}^2 + 0.801137 \sigma_{t-1}^2 \quad (4.3)
 \end{aligned}$$

Dari persamaan (4.3) dapat diperoleh prediksi nilai volatilitas dari model GARCH(1,1). Dengan grafik sebagai berikut :



Gambar 4.2 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan model GARCH(1,1)

Pada gambar 4.2 terlihat bahwa hasil prediksi volatilitas dengan model GARCH(1,1) sedikit

berada di atas volatilitas data acuan. Namun mendekati akhir grafik pada periode ke-850 sampai 969 hasil prediksi sangat mendekati nilai volatilitasnya.

4.3 Artificial Neural Networks – Generalized Autoregressive Conditional Heteroscedasticity

Model ANN-GARCH merupakan optimasi dari model GARCH(1,1) dengan menggunakan model ANN. Didalam model ANN-GARCH(1,1) ini, model GARCH(1,1) dijadikan inputan model ANN. Persamaan (4,3) dijadikan *input* dalam model ANN yaitu $\hat{\sigma}_t^2$ dan \hat{X}_t^2 , dan sebagai target σ_t^2 .

Pada pengujian model ANN-GARCH(1,1) digunakan beberapa skenario pengujian sebagai berikut:

Skenario	Arsitektur		
	Input Neuron	Hidden Neuron	Output Neuron
1	2	2	1
2	2	4	1
3	2	6	1
4	2	8	1
5	2	10	1
6	2	12	1
7	2	14	1
8	2	16	1

Tabel 4.2 Skenario Arsitektur ANN

Pada tabel 4.2 terdapat 3 skenario pengujian dengan jumlah *input neuron* dan *output neuron* yang sama, sedangkan untuk *hidden neuron* pada setiap skenario berbeda yaitu 2, 4, 6, 8, 10, 12, 14, dan 16 *hidden neuron*.

Arsitektur yang digunakan pada tabel 4.2, selanjutnya menggunakan parameter-parameter


input dalam *training* dan *testing* parameter-parameter tersebut adalah :

Parameter	Nilai Uji
Maksimum Epochs (iterasi)	1000
MSE training dan testing	0.01
Learning Rate	0.01


Tabel 4.3 Inisialisasi Parameter model ANN-GARCH(1,1)

Pada setiap skenario dilakukan 5 kali percobaan dengan menggunakan parameter yang sama untuk memperoleh hasil terbaik.


Data hasil prediksi dengan model GARCH(1,1) dibagi menjadi *training*, *validasi*, dan *testing* dengan masing-masing komposisi yaitu 60% *training*, 15% *validasi*, dan 25% *testing* dari jumlah 969 data prediksi model GARCH(1,1). Dari pengujian model ANN-GARCH(1,1) untuk prediksi volatilitas diperoleh hasil terbaik sebagai berikut :




Gambar 4.3 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan Model ANN-GARCH(1,1) Skenario 1




Gambar 4.4 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan Model ANN-GARCH(1,1) Skenario 2




Gambar 4.5 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan Model ANN-GARCH(1,1) Skenario 3




Gambar 4.9 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan Model ANN-GARCH(1,1) Skenario 7



Gambar 4.6 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan Model ANN-GARCH(1,1) Skenario 4




Gambar 4.10 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan Model ANN-GARCH(1,1) Skenario 8



Gambar 4.7 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan Model ANN-GARCH(1,1) Skenario 5

Berdasarkan pada gambar 4.3, 4.4, 4.5, 4.6, 4.7, 4.8, 4.9, dan 4.10 hasil prediksi volatilitas dengan model ANN-GARCH(1,1) sangat mendekati volatilitas data acuan. Bila dibandingkan dengan gambar 4.2 hasil prediksi volatilitas mengalami kenaikan yang cukup signifikan.



Gambar 4.8 Grafik Perbandingan Volatilitas dan Volatilitas Prediksi dengan Model ANN-GARCH(1,1) Skenario 6

4.4 Hasil Perhitungan Validasi Model

Validasi model digunakan untuk memilih model terbaik dengan melihat *error* dari masing-masing model yang telah diuji. Semakin kecil *error* yang dihasilkan oleh model tersebut semakin baik untuk digunakan memprediksi periode berikutnya. Berikut merupakan hasil perhitungan MAE dan RMSE menggunakan model GARCH(1,1) dan ANN-GARCH(1,1) :

Hasil Perhitungan MAE dan RMSE		
Model	MAE	RMSE
GARCH(1,1)	7.9885e-08	2.4867e-06
ANN-GARCH skenario 1	3.7302e-07	1.1612e-05

ANN-GARCH skenario 2	5.4209e-08	1.6875e-06
ANN-GARCH skenario 3	1.6117e-08	5.0169e-07
ANN-GARCH skenario 4	1.7530e-08	5.4569e-07
ANN-GARCH skenario 5	3.9132e-08	1.2181e-06
ANN-GARCH skenario 6	1.1249e-08	3.5016e-07
ANN-GARCH skenario 7	4.3873e-08	1.3657e-06
ANN-GARCH skenario 8	2.5220e-08	7.8508e-07

Tabel 4.4 Hasil Perhitungan Validasi Model

Dari tabel 4.4 diperoleh hasil terbaik menggunakan model ANN-GARCH(1,1) dengan skenario 6 dengan nilai MAE = 1.1249e-08 dan RMSE = 3.5016e-07. Berdasarkan hasil tersebut penambahan jumlah *hidden neuron* cenderung tidak berdampak besar pada hasil RMSE dan MAE. Pada model GARCH(1,1) *error* yang diperoleh tidak sebaik model ANN-GARCH(1,1) dengan jumlah *hidden neuron* lebih dari 2 dikarenakan pada model GARCH(1,1) tidak dapat melakukan proses pembelajaran atau *learning*.

5. Kesimpulan dan Saran

5.1 Kesimpulan

Kesimpulan yang didapat dari Tugas Akhir ini adalah:

1. Berdasarkan hasil pengujian ANN-GARCH(1,1) melalui beberapa skenario yang dilakukan, penambahan jumlah *hidden neuron* tidak terlalu berdampak besar pada hasil yang didapatkan.
2. Untuk hasil prediksi volatilitas, model ANN-GARCH(1,1) dengan jumlah *hidden neuron* lebih dari 2 lebih baik dari

pada model GARCH(1,1), terlihat dari hasil MAE dan RMSE masing-masing sebesar 1.1249e-08 dan 3.5016e-07.

5.2 Saran

Saran yang bisa penulis berikan setelah pengerjaan Tugas Akhir ini adalah:

1. Untuk penelitian selanjutnya sebaiknya menggunakan model GARCH dengan orde yang lain untuk hasil prediksi yang lebih baik.
2. Menggunakan model lain untuk mengoptimasi model GARCH sehingga dapat ditemukan model baru yang lebih baik untuk dikombinasikan oleh model GARCH.
3. Model ANN-GARCH(1,1) dapat menjadi salah satu pertimbangan bagi para investor untuk memprediksi volatilitas suatu saham.

Referensi

- [1] Hugida, Lydianta (2011). *Analisis Faktor-Faktor Yang Mempengaruhi Volatilitas Harga Saham*. Skripsi. Universitas Diponegoro.
- [2] Tsay, Ruey S. 2005. *Analysis of Financial Time series*. Graduate School of Business, University of Chicago, USA.
- [3] Jorion, Philippe. (2007). *Financial Risk Manager Handbook*. New Jersey. John Wiley & Sons.
- [4] Bollerslev, T., (1986). *Generalized Autoregressive Conditional Heteroscedasticity*. *Journal of Econometrics*.
- [5] Suyanto. (2008). *Soft Computing*. Indonesia. Informatika Bandung.
- [6] Ramadhani, T.R. (2013). *Penerapan Model Neuro-GARCH untuk Peramalan Data Saham*. Skripsi. Universitas Brawijaya.

- [7] Kristjanpoller Werner, Minutolo M.C. (2016). *Forecasting volatility of oil price using an Artificial Neural Network-GARCH model. Expert System With Application.*
- [8] Chai, T. Draxler, R. R. 2014. *Root mean square error (RMSE) or Mean absolute error(MAE)? Arguments Against Avoiding RMSE in the Literature.* University Research Court, Clollege Park. USA.
- [9] Kristjanpoller Werner, Minutolo M.C. (2015). *Gold price volatility: A forecasting approach using the Artificial Neural Network-GARCH model. Expert System With Application.*
- [10] Magnus F.R., Fosu A.E., (2006). *Modelling and Forecasting Volatility of Returns on the Ghana Stock Exchange Using Garch Models. Journal of Applied Science.*
- [11] Prajoko, A.A. (2012). *Pengukuran Value At Risk Individual Dan Portofolio Saham Bursa Efek Indonesia Dan Indeks Saham Bursa Efek Di Negara Negara Asia. Thesis.* Universitas Indonesia.

Telkom
University