

## MODEL JARINGAN SYARAF RBF-FA-EGARCH UNTUK PERAMALAN DATA TIME SERIES

**Asri Bakti Pratiwi**

Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Airlangga Surabaya  
Alamat e-mail : asri.bekti@gmail.com

### ABSTRAK

Model Jaringan Syaraf RBF-FA-EGARCH merupakan gabungan antara model Jaringan Syaraf *Radial Basis Function* dan model peramalan Exponential Generalized Heteroscedastic dengan optimasi hasil error peramalan menggunakan algoritma *Firefly Algorithm*. Model Jaringan Syaraf RBF-FA-EGARCH menerapkan prosedur iteratif untuk memilih variabel penjelas berdasarkan pengurangan dari error peramalan dan menggunakan algoritma K-means untuk memperoleh nilai center dari Jaringan Syaraf RBF. Maximum Likelihood Estimator (MLE) digunakan untuk memperoleh bobot jaringan dan hasil estimasi parameter dari model EGARCH. Algoritma *Firefly Algorithm* mengoptimasi error hasil peramalan berdasarkan nilai center, bobot dan parameter dari model. Berdasarkan hasil penerapan pada data return saham harian Bank Rakyat Indonesia Tbk on 11 November 2003 – 11 March 2011 untuk meramalkan data 7 hari kedepan diperoleh hasil bahwa model tersebut berhasil meminimalkan error hasil peramalan dengan nilai RMSE sebesar 0,0011.

**Kata Kunci** : peramalan, RBF-EGARCH, firefly algorithm, jaringan syaraf

### PENDAHULUAN

Model *time series* telah dikenal dengan baik untuk tujuan peramalan kejadian di masa yang akan datang. Dalam analisis data makro-ekonomi, sebagian besar deret waktu biasanya menunjukkan suatu lonjakan-lonjakan variansi yang besar pada suatu periode tertentu sehingga asumsi variansi *error* konstan tidak dipenuhi [1]. Data *time series* dengan variansi *error*nya yang tidak homogen di setiap waktunya dinamakan data *time series* dengan *conditional heteroscedastic*. Beberapa metode telah digunakan untuk mengatasi masalah *heteroscedastic* diantaranya adalah model *Autoregressive Conditional Heteroscedastic* (ARCH) yang dikenalkan dengan pertama kali oleh Engle [2]. Kemudian Bollerslev

mengembangkan model *Generalized Autoregressive Conditional Heteroscedastic* (GARCH) [3]. Kemudian model *Exponential Generalized Autoregressive Conditional Heteroscedastic* (EGARCH) dikembangkan oleh Nelson (1991) [4]. Model *conditional heteroscedastic* tersebut telah banyak digunakan untuk memodelkan variansi *error* dari suatu model *time series* ARIMA ketika variansi *error*nya tidak homogen.

Tujuan utama permodelan data *time series* adalah agar dapat dilakukan peramalan terhadap data-data yang akan datang. Keakuratan hasil prediksi sangat diperlukan terutama dalam pengambilan keputusan dalam banyak bidang khususnya ekonomi. Kasus *heteroscedastic* sering ditemukan pada

data harga saham yang variansi *error* konstan tidak dipenuhi [2].

Beberapa peneliti telah mengembangkan model peramalan dengan menggabungkan beberapa metode peramalan dengan jaringan syaraf tiruan. Kamstra dan Donaldson menggabungkan *Generalized Autoregressive Conditional Heteroscedastic* (GARCH) dengan *Artificial Neural Network* (ANN), dikenal dengan NN-GARCH [5]. Suatu model gabungan antara Fungsi Basis Radial (RBF) dan NN-GARCH atau dikenal dengan model RBF-NN-GARCH diteliti oleh Coelho dan Santos [6].

Xin-She Yang mengenalkan algoritma kunang-kunang atau *Firefly Algorithm* (FA). Algoritma kunang-kunang adalah algoritma metaheuristik yang terinspirasi dari perilaku kedip cahaya kunang-kunang. Terdapat dua fungsi dasar kedip cahaya tersebut, yaitu untuk menarik perhatian kunang-kunang yang lain (komunikasi) dan untuk menarik mangsa [7].

Dalam penelitian ini dilakukan kajian mengenai mengenai penggabungan dua model yaitu model jaringan syaraf RBF dengan model EGARCH dengan optimasi error dari hasil permalan dengan menggunakan algoritma kunang-kunang. Dalam hal ini model RBF menggantikan model ARIMA yang biasanya digabungkan dengan model EGARCH. Varians *error* dari model RBF dimodelkan dengan menggunakan model EGARCH. Nilai dari parameter bobot, center dan lebar dari jaringan syaraf RBF dioptimasi menggunakan algoritma kunang-kunang untuk mendapatkan error yang minimum

## METODE PENELITIAN

### Sumber Data dan Variabel Penelitian

Sampel data adalah *return* saham harian Bank Rakyat Indonesia Tbk

(BBRIJK) antara 11 November 2003 – 11 Maret 2011 dengan jumlah data sebanyak 1911 pengamatan yang memiliki variansi error *heteroscedastic*. Sebanyak 80% data pertama yaitu 1531 data pengamatan digunakan untuk mengestimasi parameter model Jaringan Syaraf RBF-GARCH dan 20% sisanya yaitu 380 data pengamatan digunakan untuk peramalan *out-sample* dan sebagai validasi model.

### Metode Analisis

Misalkan  $\mathbf{z}_t = (z_{1t}, z_{2t}, \dots, z_{qt})' \subseteq \mathbb{R}^q$  adalah vektor yang memuat  $q$  variabel penjelas (variabel prediktor) bagi respon  $y_t \in \mathbb{R}, t = 1, \dots, T$ . Dimisalkan hubungan antara  $y_t$  dan  $\mathbf{z}_t$  mengikuti model dengan bentuk

$$y_t = \mathbb{E}[y_t | \mathbf{z}_t] + \varepsilon_t = f(\mathbf{z}_t) + \varepsilon_t \quad (1)$$

maka model Jaringan Saraf Fungsi Basis Radial merupakan pendekatan dari model dari persamaan (1), yaitu

$$y_t = \sum_{i=1}^m w_i \varphi(\|\mathbf{z}_t - \mu_i\|) + \varepsilon_t \quad (2)$$

dengan  $\mathbf{z}_t$  merupakan variabel penjelas,  $\mu_i$  adalah *center* atau pusat atas fungsi basis ke- $i$  dan  $w_i$  adalah bobot atas fungsi basis ke- $i$ . Fungsi  $\varphi(\cdot)$  adalah fungsi aktivasi yang pada jaringan saraf Fungsi Basis Radial biasa disebut sebagai fungsi basis. Fungsi basis Gaussian [6] didefinisikan sebagai berikut

$$\varphi_j(x) = \exp\left(-\frac{x^2}{2\sigma_j^2}\right) \quad (3)$$

dengan  $\sigma_j$  adalah lebar dari fungsi basis.

Model Jaringan Syaraf RBF-EGARCH merupakan gabungan dari model Jaringan Syaraf Fungsi Basis Radial dengan model *heteroscedastic*, yaitu model *Exponential GARCH* (EGARCH). Model EGARCH (1,1) didefinisikan sebagai berikut

$$\varepsilon_t = u_t \sqrt{h_t}, u_t \sim N(0,1) \quad (4)$$

$$\ln h_t = \omega + \delta \ln h_{t-1} + \tau \frac{|\varepsilon_{t-1}|}{\sqrt{h_{t-1}}} + \rho \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}}$$

dengan  $\varepsilon_t$  adalah *error* suatu model dan  $h_t$  merupakan variansi dari *error* tersebut.

Sehingga model Jaringan Syaraf RBF-EGARCH dapat dinyatakan dalam bentuk sebagai berikut

$$y_t = \sum_{i=1}^m w_i \varphi(\|z_t - \mu_i\|) + \varepsilon_t \quad (5)$$

$$\varepsilon_t = u_t \sqrt{h_t}, \quad u_t \sim N(0,1)$$

$\ln h_t = \omega + \delta \ln h_{t-1} + \tau \frac{|\varepsilon_{t-1}|}{\sqrt{h_{t-1}}} + \rho \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}}$   
dengan  $\varphi(\cdot)$  adalah fungsi pada persamaan (3).

Pembentukan model Jaringan Saraf RBF-FA-EGARCH terdiri dari lima tahapan. Tahapan pertama adalah penentuan variabel penjelas  $z_t$  yang relevan. Kedua adalah penentuan *center* pada jaringan syaraf Fungsi Basis Radial. Ketiga adalah perhitungan nilai fungsi basis untuk mendapatkan tahapan yang keempat, yaitu perhitungan bobot serta estimasi parameter EGARCH. Tahapan terakhir adalah optimasi nilai parameter dengan menggunakan algoritma kunang-kunang.

### Langkah-langkah Penelitian

#### A. Pemilihan Variabel Penjelas

Penentuan variabel input dalam peramalan data *time series* merupakan salah satu permasalahan utama dalam penerapan Jaringan Syaraf Tiruan. Tidak semua lag variabel dapat digunakan sebagai input, karena beberapa variabel mungkin tidak relevan sehingga dapat menyebabkan dimensi input terlalu tinggi, meningkatkan kompleksitas komputasi dan kebutuhan memori [8]. Variabel penjelas yang terpilih (relevan) adalah variabel yang memberikan pengurangan *error* peramalan cukup besar pada peramalan *in-sample* dengan menggunakan jaringan saraf RBF. Pada tahapan ini, algoritma clustering K-means digunakan untuk mengelompokkan unit input ke dalam beberapa cluster dan mendapatkan center untuk masing-masing cluster. Untuk

memperoleh nilai bobot yang optimal digunakan metode *least square*.

Tahapan :

Langkah 1 : Untuk  $k$  berjalan dari 1 sampai *lag*, lakukan :

Langkah 2 : Bentuk matriks unit input,  $X$  dengan  $Y_t$  vektor training, yaitu

$$X = [y_{t-1}, y_{t-2}, \dots, y_{t-k}] \quad (4.5)$$

Langkah 3 : Hitung jumlah unit *hidden* yang optimal berdasarkan algoritma *clustering* K-means. Dapatkan *center* dari setiap unit *hidden*.

Langkah 4 : Hitung lebar dari setiap unit *hidden* (cluster) berdasarkan jarak Euclidean antara *center*  $\mu_j$  dan persekitaran terdekatnya, yaitu

$$\sigma_j = \min \{ \alpha \| \mu_j - \mu_i \| \mid i \neq j \}$$

dengan  $\alpha$  adalah *learning rate*

Langkah 5 : Dapatkan output berupa matriks  $A$  dari layer *hidden* dengan menggunakan fungsi aktivasi Gaussian, dengan  $A_{ij}$  merupakan output dari input input ke- $i$  unit *hidden* ke- $j$ .

Langkah 6 : Hitung bobot antara layer *hidden* dan output dengan menggunakan *least square*, yaitu  $w = (A^T A)^{-1} A^T y$ , dengan  $y$  adalah target.

Langkah 7 : Dapatkan estimasi output target, yaitu  $y = Aw$ .

Langkah 8 : Hitung *error* output. Jika terdapat pengurangan *error* apabila dibandingkan dengan  $k-1$ , pilih  $y_{t-k}$

**B. Penentuan Center Unit Hidden**

Algoritma clustering K-means digunakan dalam penentuan jumlah cluster yang optimal serta nilai center dari masing-masing cluster pada jaringan saraf Fungsi Basis Radial.

Algoritma dari metode *clustering* K-means [9] dengan  $n$  unit input adalah sebagai berikut :

Langkah 1 : Pilih  $l < n$  cluster

Langkah 2 : Ambil sejumlah  $l$  learning data yang pertama  $x_1, x_2, \dots, x_l$  sebagai vektor center :

$$\mu_j = x_j, \quad j = 1, 2, \dots, l$$

Langkah 3 : Kelompokkan  $x_i$  ( $i = l + 1, l + 2, \dots, n$ ) kedalam salah satu cluster berdasarkan criteria jarak terkecil :  $x_i$  masuk kesalah satu cluster ke- $j$  dimana

$$\|x_i - \mu_j\| = \min_j \|x_i - \mu_j\|, \quad 1 \leq j \leq l$$

Langkah 4 : Update vektor center dengan menggunakan nilai center yang baru, yaitu :

$$\mu_j = \frac{1}{n_j} \sum_{x_i \in j} x_i, \quad 1 \leq j \leq l$$

dengan  $n_j$  adalah jumlah learning data yang termasuk dalam cluster  $j$ .

Langkah 5 : Kelompokkan  $x_i$  ( $i = 1, 2, \dots, n$ ) kedalam salah satu cluster berdasarkan kriteria jarak terkecil pada langkah 3.

Langkah 6 : Selama masih terdapat perpindahan paling sedikit satu unit data ke dalam cluster yang berbeda, lakukan langkah 4-6.

**C. Perhitungan Lebar**

Lebar dapat pula disebut sebagai radius dalam fungsi Gaussian. Nilai lebar dapat

dihitung berdasarkan rumus standar deviasi sebagai berikut :

$$\sigma = \sqrt{\frac{\sum_{i=1}^m (\mu_i - \bar{\mu})^2}{m-1}}$$

dengan  $\mu_i$  ( $i = 1, 2, \dots, m$ ) adalah center,  $\bar{\mu}$  adalah rata-rata center dan  $m$  adalah banyaknya center yang terpilih. Setelah nilai center dan lebar diketahui maka dapat diperoleh fungsi radial basisnya dengan menggunakan fungsi yang digunakan untuk membawa input menuju output yang diinginkan, yaitu fungsi Gaussian pada persamaan (3).

**D. Estimasi Bobot dan Parameter EGARCH**

Estimasi parameter model Jaringan Syaraf RBF-FA-EGARCH, yaitu parameter  $\theta = (\theta_M, \theta_V)'$ , dengan  $\theta_M = (w_1, \dots, w_m)'$  yang merupakan parameter bobot pada model jaringan syaraf Fungsi Basis Radial dan  $\theta_V = (\omega, \delta, \tau, \rho)'$  yang merupakan parameter model GARCH, dapat dilakukan dengan menggunakan metode Maximum Likelihood [10].

Diasumsikan distribusi bersyarat  $f(y_t | y_{t-1}, \dots, y_1, \theta)$  adalah normal dengan mean  $\hat{y}_t$  dan variansi  $\hat{h}_t$  dengan  $\theta$  adalah vektor parameter dalam  $\hat{y}_t$  dan  $\hat{h}_t$ . Maka fungsi *likelihood* bersyaratnya adalah

$$\begin{aligned} f(y_1, \dots, y_T; \theta) &= f(y_1; \theta) \prod_{t=2}^T \frac{1}{\sqrt{2\pi h_t}} \exp \left[ -\frac{1}{2} \frac{\varepsilon_t^2}{h_t} \right] \\ &= f(y_1; \theta) \prod_{t=2}^T \frac{1}{\sqrt{2\pi h_t}} \exp \left[ -\frac{1}{2} \frac{(y_t - \hat{y}_t)^2}{h_t} \right] \\ &= \left[ \frac{1}{\sqrt{2\pi}} \right]^T f(y_1; \theta) \prod_{t=2}^T \frac{1}{\sqrt{h_t}} \exp \left[ -\frac{1}{2} \frac{(y_t - \hat{y}_t)^2}{h_t} \right] \end{aligned}$$

dengan  $f(y_1; \theta)$  adalah fungsi kepadatan probabilitas saat pengamatan pertama, yaitu  $y_1$ . MLE untuk  $\theta$  (dinotasikan dengan  $\hat{\theta}$ ) adalah nilai  $\theta$  yang memaksimumkan fungsi *likelihood*-nya. Jika fungsi *likelihood* dinyatakan dengan

$L$ , maka fungsi *log likelihood* nya adalah sebagai berikut

$$\begin{aligned} \ln L &= \ln f(y_1, \dots, y_T; \theta) \\ &= \ln(2\pi)^{-T/2} + \ln f(y_1; \theta) + \\ &\ln \left( \prod_{t=2}^T \frac{1}{\sqrt{h_t}} \exp \left[ -\frac{1}{2} \frac{(y_t - \hat{y}_t)^2}{h_t} \right] \right) \\ &= \ln(2\pi)^{-T/2} + \ln f(y_1; \theta) + \\ &\sum_{t=2}^T \ln(h_t)^{-1/2} - \frac{1}{2} \sum_{t=2}^T \frac{(y_t - \hat{y}_t)^2}{h_t} \\ &= -\frac{T}{2} \ln(2\pi) + \ln f(y_1; \theta) - \\ &\frac{1}{2} \sum_{t=2}^T \ln(h_t) - \frac{1}{2} \sum_{t=2}^T \frac{(y_t - \hat{y}_t)^2}{h_t} \end{aligned}$$

Untuk mempermudah proses estimasi, persamaan ada model jaringan syaraf Fungsi Basis Radial dapat pula dituliskan dalam bentuk persamaan regresi sebagai berikut

$$y = \boldsymbol{\varphi} \boldsymbol{\theta}_M + \varepsilon$$

dengan  $\boldsymbol{\varphi} = (y_1, y_2, \dots, y_T)'$ ,  $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_T)'$ ,  $\boldsymbol{\theta}_M = (w_1, \dots, w_m)'$  dan  $\boldsymbol{\varphi} =$

$$\begin{pmatrix} \varphi(\|z_1 - \mu_1\|) & \cdots & \varphi(\|z_1 - \mu_m\|) \\ \vdots & \ddots & \vdots \\ \varphi(\|z_T - \mu_1\|) & \cdots & \varphi(\|z_T - \mu_m\|) \end{pmatrix}$$

Dengan  $\varphi$  adalah tetap (*fixed*), maka nilai awal dari vektor parameter  $\boldsymbol{\theta}_M$  dapat diestimasi dengan

$$\hat{\boldsymbol{\theta}}_{0,M} = (\boldsymbol{\varphi}'\boldsymbol{\varphi})^{-1} \boldsymbol{\varphi}'\mathbf{y}$$

#### E. Optimasi Error Peramalan dengan menggunakan Algoritma Kunang-kunang

Algoritma kunang-kunang digunakan untuk mengoptimalkan nilai parameter model Jaringan saraf RBF-FA-EGARCH yaitu nilai center, lebar dan bobot [11].

Inisialisasi posisi awal kunang-kunang dibangkitkan secara random dengan interval yang diperoleh dari proses training pada jaringan saraf RBF yang nantinya merupakan nilai yang mengoptimalkan error peramalan. Proses training dari jaringan saraf RBF digunakan untuk mendapatkan interval awal kunang-kunang. Yaitu  $\mathbf{x}_{opt} = (\mu_{op},$

$\sigma_{op}, w_{op})$ , dengan  $\mu_{op} \in [-\mu, \mu]$ ,  $\sigma_{op} \in [-\sigma, \sigma]$ , dan  $w_{op} \in [-w, w]$ . Fungsi objektif dihitung dengan menggunakan RMSE, yaitu

$$RMSE = \sqrt{\frac{\sum_{t=1}^m (y_t - \hat{y}_t)^2}{m}}$$

dengan  $(y_t - \hat{y}_t)$  adalah *error* peramalan untuk  $m$  pengamatan.

Setelah mendapatkan nilai error peramalan, maka dilakukan perangkingan posisi kunang-kunang berdasarkan hasil fungsi objektif, yaitu nilai RMSE yang paling kecil. Kemudian semua kunang-kunang akan bergerak menuju kunang-kunang yang memiliki nilai fungsi objektif lebih kecil, yaitu kunang-kunang yang memiliki intensitas cahaya lebih terang.

Pada kunang-kunang yang berdekatan maka akan timbul daya tarik yang dirumuskan pada persamaan :

$$\beta = \beta_0 e^{-\gamma r^2}$$

$\beta_0$  adalah daya tarik saat jarak  $r = 0$ , sedangkan  $\gamma$  merupakan koefisien penyerapan cahaya. Pergerakan kunang-kunang  $i$  bergerak menuju tingkat intensitas cahaya yang terbaik ditentukan sebagai berikut :

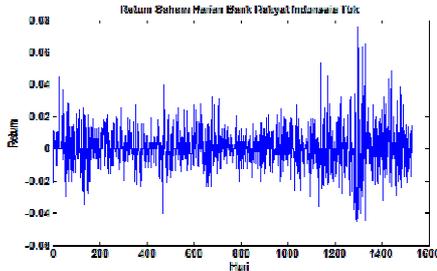
$$x_i^{t+1} = x_i^t + \beta_0 e^{-\gamma r_{ij}^2} (x_j^t - x_i^t) + \alpha \left( \text{rand} - \frac{1}{2} \right)$$

$\alpha$  adalah parameter pengacak dan *rand* adalah nilai acak yang dibangkitkan dari distribusi Uniform [0,1].

## HASIL PENELITIAN

Sampel data adalah *return* saham harian Bank Rakyat Indonesia Tbk (BBRIJK) antara 11 November 2003 – 11 Maret 2011 dengan jumlah data sebanyak 1911 pengamatan yang memiliki variansi error *heteroscedastic*. Sebanyak 80% data pertama yaitu 1531 data pengamatan digunakan untuk

mengestimasi parameter model Jaringan Syaraf RBF-GARCH dan 20% sisanya yaitu 380 data pengamatan digunakan untuk peramalan *out-sample* dan sebagai validasi model. Gambar 1 menyajikan plot data dari *return* saham harian Bank Rakyat Indonesia.



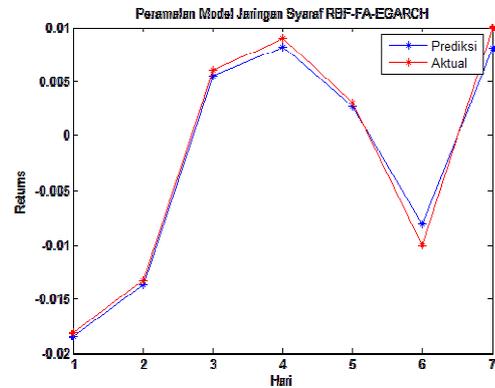
Gambar 1 Plot Return Saham Bank Rakyat Indonesia

Dari perhitungan iteratif seleksi variabel penjelas berdasarkan error peramalan yang paling kecil, diperoleh 8 inputan yang merupakan variabel penjelas terbaik yang digunakan dalam peramalan data *return* saham Bank Rakyat Indonesia Tbk adalah

$z_t = (y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}, y_{t-6}, y_{t-10}, y_{t-14}, y_{t-24})$  Dari hasil simulasi peramalan pada data *return* saham Bank Rakyat Indonesia, Tbk dapat disimpulkan bahwa model Jaringan Syaraf RBF-FA-EGARCH memberikan performansi lebih baik daripada model peramalan ARIMA-EGARCH, sehingga model tersebut dapat dijadikan alternatif model peramalan data time series *heteroscedastic*.

Hasil peramalan untuk 7 hari kedepan model Jaringan Syaraf RBF-FA-EGARCH disajikan pada Gambar 2. Peramalan dengan menggunakan model RBF-FA-EGARCH memberikan RMSE sebesar 0,0011 seperti yang disajikan disajikan dalam Tabel 1. Berdasarkan Tabel 1, optimasi error peramalan model Jaringan

Saraf RBF-FA-EGARCH dengan menggunakan algoritma kunang-kunang memberikan peningkatan keakuratan hasil peramalan.



Gambar 2 Plot Hasil Peramalan model RBF-FA-EGARCH

Tabel 1 RMSE Hasil Peramalan

MODEL	RMSE 7 HARI KEDEPAN
ARIMA-EGARCH	0.0104
Jaringan Saraf RBF-FA-EGARCH	0.0011

**KESIMPULAN**

Dari hasil simulasi peramalan pada data *return* saham Bank Rakyat Indonesia, Tbk dapat disimpulkan bahwa model Jaringan Syaraf RBF-FA-EGARCH memberikan performansi lebih baik daripada model peramalan ARIMA-EGARCH, sehingga model tersebut dapat dijadikan alternatif model peramalan data time series *heteroscedastic*.

**DAFTAR PUSTAKA**

[1] Enders, W., 1995, *Applied Econometric Time Series*, John Willey & Sons. Inc, Canada.  
 [2] Engle, R. F., 1982, 'Autoregressive Conditional Heteroscedasticity With Estimates of the Variance of United Kingdom Inflation, *Econometrica* **40**, 987-1007.

- 
- 
- [3] Bollerslev, T., 1986, Generalized Autoregressive Conditional Heteroscedasticity, *Journal of Econometrica* **31**, 307-327.
- [4] Nelson, D. B., 1991, Conditional heteroskedasticity in asset returns: A new approach, *Econometrica* **59**, 347-370.
- [5] Kamstra, M. J. dan Donaldson, G., 1997, An Artificial Neural Network GARCH Model for International Stock Market Volatility, *Journal of Empirical Finance* **4.1**, 17-46.
- [6] Coelho, L. dan Santos, A., 2010, A RBF Neural Network Model with GARCH Errors : Application to Electricity Price Forecasting. *Electric Power Systems Research* **81**, 74-83.
- [7] Xin-She Yang., 2010, *Nature-Inspired Metaheuristic Algorithms*. Second Edition. Luniver Press, United Kingdom.
- [8] Zheng, G.L. dan Billings, S.A., 1996, Radial Basis Function Configuration Using Mutual Information and the Orthogonal Least Square Algorithm, *Neural Networks* **9**, 1619-1637.
- [9] Gupta, M. M., Jin, L., dan Homma, N. 2003. *Static and Dynamic Neural Networks : From Fundamentals to Advanced*, John Wiley & Sons, Inc., Canada.
- [10] Medeiros, M., McAleer, M., Slottje, D., Ramos, V. dan Rey-Maquiera, J., 2008, 'An Alternative Approach to Estimating Demand : Neural Network Regression with Conditional Volatility for High Frequency Air Passenger Arrivals', *Journal of Econometrics* **147**, 378-382.
- [11] Tao Xiong, Yukun Bao dan Zhongyi Hu, 2014, Multiple-output support vector regression with a firefly algorithm for interval-valued stock price index forecasting, *Knowledge-Based Systems* **55**, 87-100.