

Pemodelan Volatilitas Saham Menggunakan Jaringan Syaraf Tiruan dan Algoritma Genetika

Hasbi Yasin¹

¹Jurusan Statistika Undip, hasbiyasin@undip.ac.id

Abstrak. Fluktuasi yang besar dan tidak pasti dalam peramalan saham merupakan salah satu masalah yang dihadapi oleh para investor. Hal ini mengakibatkan model peramalan yang digunakan harus mampu mengakomodasi kondisi tersebut. Salah satu model yang cocok adalah model *Autoregressive Conditional Heteroscedasticity* (ARCH). Alternatif lain yang dapat digunakan adalah dengan mengkombinasikan Jaringan Syaraf Tiruan (JST) dengan model ARCH yang disebut Neuro-ARCH. Tujuan dari penelitian ini adalah menentukan model volatilitas saham menggunakan model Neuro-ARCH dengan algoritma genetika sebagai algoritma pelatihan jaringannya. Data yang digunakan adalah data harga saham PT. XL Axiata, Tbk. Pemilihan model terbaik dilakukan berdasarkan nilai RMSE dan MAPE terkecil. Hasil penelitian menunjukkan bahwa model dengan nilai probabilitas *crossover* 0.6 merupakan model terbaik dengan nilai RMSE sebesar 0.000195 dan nilai MAPE sebesar 0.005212%.

Kata Kunci: Algoritma Genetika; ARCH, JST, Volatilitas.

1 Pendahuluan

Volatilitas merupakan besarnya nilai fluktuasi dari sebuah asset, misalnya pada perdagangan saham, secara statistik volatilitas merupakan standar deviasi dari pengembalian harga (*return*) saham, dan merepresentasikan risiko pengembalian harga saham tersebut [1, 2]. Semakin besar volatilitas, semakin besar kemungkinan mengalami keuntungan atau kerugian [3]. Peningkatan volatilitas dalam pasar keuangan pada dekade terakhir menyebabkan para peneliti, praktisi dan regulator merancang dan mengembangkan alat ukur dalam Managemen Risiko.

Data return saham biasanya memiliki variansi yang tidak konstan di setiap titik waktunya [4]. Kondisi data yang seperti ini disebut heteroskedastisitas bersyarat (*conditional heteroscedasticity*). Model runtun waktu finansial yang dapat mengakomodasi heteroskedastisitas salah satunya adalah model *Autoregressive Conditional Heteroscedasticity* (ARCH) [1]. Sedangkan model yang lebih fleksibel untuk pemodelan variansi yang tidak konstan adalah model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) [5]. Struktur GARCH terdiri dari dua persamaan, yaitu persamaan mean bersyarat yang merupakan model standard ARCH dan persamaan variansi bersyarat yang memungkinkan variansi berubah setiap waktu [6]. Model tersebut akan mengalami penurunan performa ketika diterapkan untuk estimasi volatilitas data keuangan yang memuat ketidakpastian dan kekurangteraturan.

Salah satu alternatif untuk mengatasi permasalahan diatas adalah dengan mengkombinasikan model ARCH dengan model Jaringan Syaraf Tiruan, dimana model ARCH berperan dalam penentuan variabel input dalam model JST. Penggunaan JST dalam peramalan data *time series* dapat menjadi solusi yang baik, namun yang menjadi masalah adalah arsitektur jaringan dan pemilihan metode pelatihan yang tepat. Salah satu pilihan yang mungkin adalah menggunakan algoritma genetika. Algoritma genetika adalah suatu algoritma pencarian stokastik berdasarkan cara kerja melalui mekanisme seleksi alam dan genetik yang bertujuan untuk mendapatkan solusi dari suatu masalah. Algoritma ini dapat digunakan sebagai metode pembelajaran dalam melatih model *Feed Forward Neural Network* (FFNN). Penerapan algoritma genetika dan JST untuk peramalan *time series* bertujuan untuk mendapatkan bobot-bobot yang optimum dengan meminimumkan *error*. Oleh karena itu, integrasi antara JST dan AG untuk peramalan *time series* memberikan keuntungan dari kedua metode tersebut. Kombinasi pemodelan JST dengan algoritma pelatihan AG memberikan hasil yang baik dan lebih akurat untuk peramalan *time series* dibandingkan dengan metode konvensional [7]. Oleh karena itu dalam penelitian ini akan dilakukan pemodelan berdasarkan kombinasi model ARCH, FFNN dan AG untuk pemodelan nilai volatilitas return saham PT. XL Axiata, Tbk.

2 Tinjauan Pustaka

2.1 Model ARCH

Secara umum model ARCH berorde q digunakan untuk membentuk model varians bersyarat (σ_t^2) pada waktu ke-t berdasarkan nilai kuadrat error pada waktu ke $t-1$ hingga $t-q$. Misalkan model rataan adalah:

$$X_t = \mu_t + e_t \quad (1)$$

Menurut Tsay[2] bahwa μ_t merupakan nilai harapan X_t bersyarat F_{t-1} , dengan:

$F_{t-1} = \{X_{t-1}, X_{t-2}, X_{t-3}, \dots, X_2, X_1\}$. Sehingga model ARMA dari X_t adalah:

$$\begin{aligned} \mu_t &= E(X_t | F_{t-1}) \\ &= \theta_0 + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} \end{aligned}$$

dengan:

X_t = return pada waktu ke-t

F_{t-1} = seluruh himpunan informasi pada waktu ke-1 sampai ke- t-1

μ_t = nilai harapan X_t bersyarat F_{t-1}

e_t = residual ARIMA pada waktu ke-t

Tsay menyatakan bahwa model ARCH adalah sisaan e_t dari model ARIMA yang pada orde tinggi akan saling berkorelasi [2], e_t dapat diuraikan sebagai berikut:

$$e_t = \varepsilon_t \sigma_t \quad e_t | F_{t-1} \sim iidN(0, \sigma_t^2)$$

$$\varepsilon_t \sim iidN(0,1)$$

Diperoleh varians bersyarat bagi e_t :

$$\begin{aligned}\text{Var}(e_t | F_{t-1}) &= E(e_t^2 | F_{t-1}) \\ &= E(\varepsilon_t^2 \sigma_t^2 | F_{t-1}) \\ &= \sigma_t^2 E(\varepsilon_t^2 | F_{t-1}) \\ &= \sigma_t^2\end{aligned}$$

sehingga ragam bersyarat yang mendefinisikan model ARCH dengan orde q yaitu :

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i e_{t-i}^2 \quad (2)$$

dengan $q > 0$, $\alpha_0 > 0$, dan $\alpha_i \geq 0$ untuk $i = 1, 2, 3, \dots, q$.

2.2 Aplikasi Algoritma Genetika untuk Pelatihan JST

Penggunaan Algoritma Genetika (AG) sebagai metode pembelajaran pada Jaringan Syaraf Tiruan (JST) merupakan suatu prosedur pelatihan jaringan yang terintegrasi untuk mendapatkan bobot atau parameter yang optimum sehingga menghasilkan output sesuai target yang ditentukan dengan meminimumkan *error*. Pada pemodelan *Feed Forward Neural Network* (FFNN) untuk data *time series*, input model yang digunakan adalah data masa lalu ($X_{t-1}, X_{t-2}, \dots, X_{t-p}$) dan targetnya adalah data masa sekarang (X_t). Bentuk umum model FFNN untuk data *time series* dituliskan dalam persamaan berikut:

$$X_t = \psi_0 \left\{ v_{bo} + \sum_{n=1}^H v_{no} \psi_n \left(w_{bn} + \sum_{i=1}^p w_{in} X_{t-i} \right) \right\}$$

dengan (w_{bn} , w_{in} , v_{bo} , v_{no}) adalah nilai bobot-bobot atau parameter-parameter pada FFNN sedangkan (ψ_n , ψ_0) adalah fungsi aktivasi yang digunakan pada setiap unit pemroses [8].

3 Metode Penelitian

3.1 Data

Data yang digunakan adalah data harga saham harian PT. XL Axiata, Tbk.

3.2 Langkah-langkah Analisis Data

- 1 Membuat pemodelan ARCH dari data return saham sebagai dasar penentuan input lag pada model JST,
- 2 Membuat pemodelan FFNN dengan pelatihan Algoritma Genetika untuk data return saham,
- 3 Melakukan pemilihan model terbaik berdasarkan kriteria RMSE dan MAPE.

4 Hasil dan Pembahasan

Pemodelan ARCH untuk return harga saham PT. XL Axiata, Tbk adalah ARCH(1,1). Pemodelan JST dengan Algoritma Genetika sebagai algoritma pelatihannya. Model JST yang digunakan adalah model FFNN. Menurut Fahmi, penentuan jumlah neuron pada lapisan hidden layer sesuai dapat ditentukan secara empris berdasarkan banyaknya neuron pada lapisan input dan lapisan output [9]. Berdasarkan model ARCH yang terbentuk maka model untuk return saham PT. XL Axiata, Tbk adalah FFNN dengan 1 unit neuron pada lapisan input, 3 unit neuron pada lapisan hidden layer dan 1 unit neuron pada lapisan output. Sedangkan fungsi aktivasi yang digunakan pada *hidden layer* menuju ke *output layer* adalah sigmoid biner (*sigmoid logistic*) dan fungsi aktivasi yang digunakan untuk sinyal output adalah fungsi idensitas (*purelin*). Berdasarkan arsitektur jaringan FFNN yang telah terbentuk maka jumlah bobot atau parameter yang akan diestimasi dengan menggunakan AG sebanyak 10 unit yang terdiri dari 3 bobot neuron untuk memberikan sinyal input pada *hidden layer* (w_{in}), 3 bobot bias untuk *hidden layer* (w_{bn}), 3 bobot neuron untuk menghasilkan *output layer* (v_{no}) dan 1 bobot bias untuk *output layer* (v_{bo}).

Berikut adalah hasil pelatihan dan pengujian dengan AG untuk beberapa ukuran “ p_c ”. Ukuran populasi yang ditetapkan sebesar 50 kromosom disertai kawin silang menggunakan penyilangan satu titik potong (*single point crossover*) dan mutasi dengan *default options* pada Matlab yaitu dengan probabilitas mutasi (p_m) 0.01. Setelah mencapai 20000 generasi diperoleh hasil sebagai berikut:

TABEL 1 Metode Seleksi Turnamen dengan $k = 8$

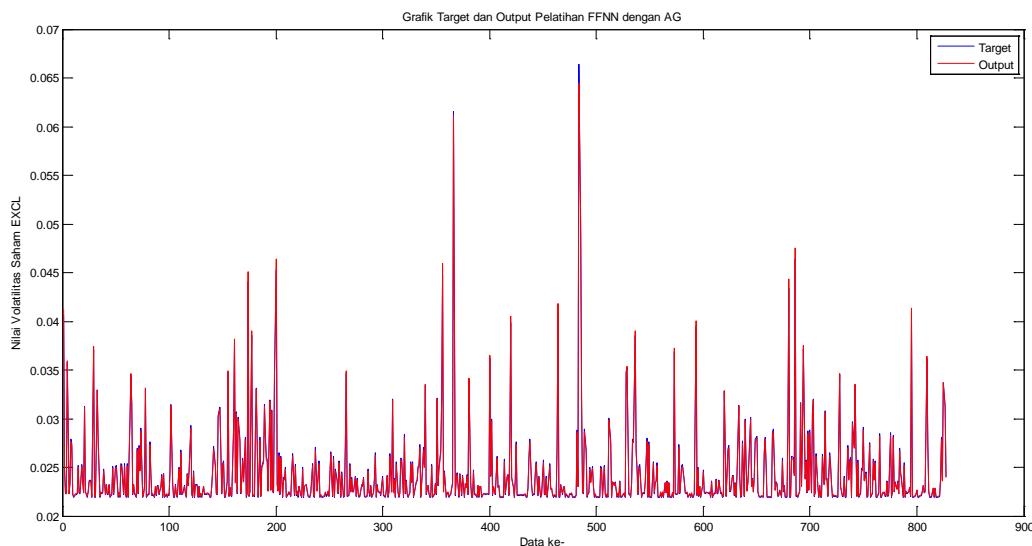
No	p_c	Volatilitas	
		RMSE	MAPE
1	0.2	0.000202	0.005504
2	0.4	0.000206	0.005621
3	0.6	0.000195	0.005212

Untuk memilih model yang terbaik adalah dengan melihat nilai RMSE dan MAPE terkecil. Berdasarkan perbandingan nilai RMSE hasil pelatihan dan pengujian dengan menggunakan metode seleksi turnamen untuk k yang berbeda-beda maka model terbaik yang digunakan adalah metode seleksi turnamen dengan $k = 8$ dan $p_c = 0.6$. Nilai bobot atau parameter optimum yang diperoleh sebagai berikut:

TABEL 2 Bobot atau parameter optimum hasil pelatihan

w_{bn}	w_{in}	v_{bo}	v_{no}
1.0000	128.9496	-2.3300	3.5813
0.9515	123.6451		-1.1261
0.4413	47.9674		1.0294

Berdasarkan persamaan FFNN tersebut maka diperoleh hasil pelatihan jaringan sebagai berikut:



Gambar 1 Perbandingan target dan output pelatihan FFNN dengan AG

5 Kesimpulan

Pemodelan ARCH dan FFNN dengan algoritma pelatihan Algoritma Genetika (AG) merupakan salah satu alternatif dalam pemodelan volatilitas return saham. Metode ini mampu menunjukkan performa yang baik dalam memodelkan volatilitas return saham. Model terbaik untuk pemodelan volatilitas saham PT. XL Axiata, Tbk adalah model dengan nilai probabilitas *crossover* 0.6 merupakan model terbaik dengan nilai RMSE sebesar 0.000195 dan nilai MAPE sebesar 0.005212%.

6 Daftar Pustaka

- [1] Engle, R.F., 1982. Autoregressive Conditional Heteroscedasticity with Estimates of Variance United Kingdom Inflation, *Econometrica*, Vol. 50, No.4. pp. 987-1007.
- [2] Tsay, 2005. *Analysis of Financial Time Series*, second Edition, Wiley Interscience, A John Wiley and Sons. Inc. Publication, USA
- [3] Holton, G, 2003, *Value at Risk, Theory and Practice*, Academic Press, Boston.
- [4] Jorion, P., 2002. *Value at Risk: The New Benchmarking for Managing Financial Risk*. Mc Graw Hill.
- [5] Bollerslev, T, 1986. Generalized Autoregressive Conditional Heteroscedasticity, *Journal of Econometrics*, 31, 307-327
- [6] Wei, W.W.S., 2006. *Time Series Analysis: Univariate and Multivariate Methods*, Second Edition, Pearson Education Inc. Boston.
- [7] Neves, J, and Cortez, P., 1998. *Combining Genetic Algorithms, Neural Networks and Data Filtering for Time Series Forecasting*. Departamento de Informatica Universidade do Minho. Portugal.
- [8] Kusumadewi, S., 2004, *Membangun Jaringan Syaraf Tiruan Menggunakan Matlab dan Excel Link*, Graha Ilmu, Yogyakarta.
- [9] Fahmi, Y. 2011. *Peramalan Nilai Harga Saham Menggunakan Jaringan Syaraf Tiruan dan Algoritma Genetik*. Yogyakarta: UII Yogyakarta.

