

PREDIKSI DATA HARGA SAHAM HARIAN MENGGUNAKAN FEED FORWARD NEURAL NETWORKS (FFNN) DENGAN PELATIHAN ALGORITMA GENETIKA (Studi Kasus pada Harga Saham Harian PT. XL Axiata Tbk)

Ira Puspita Sari¹, Triastuti Wuryandari², Hasbi Yasin³

¹Mahasiswa Jurusan Statistika FSM Universitas Diponegoro

^{2,3}Staf Pengajar Jurusan Statistika FSM Universitas Diponegoro

ABSTRACT

Artificial neural network (ANN) or Neural Network (NN) is an information processing system that has characteristics similar to biological neural networks. One of the ANN models have network is quite simple and can be applied to time series data prediction is Feed Forward Neural Networks (FFNN). In general, FFNN trained using Backpropagation algorithm to obtain weights, but performance will decrease and trapped in a local minimum when applied to data that have great complexity like financial data. The solution to this problem is to train FFNN using Genetic Algorithm (GA). GA is a search algorithm that is based on the mechanism of natural selection and genetics to determine the global optimum. Training FFNN using GA is a good solution but the problem is how to understand the workings of FFNN training using the GA, the determination of the combination of the probability of crossover (p_c), number of populations, number of generations, and the size of the tournament (k) on the AG to produce predictive value approaching actual value. One possible option is to use the technique of trial-end-error by experimenting for some combination of these four parameters. Of the 64 times the application of the AG test results to train FFNN models on daily stock price data PT. XL Axiata Tbk obtained results are sufficiently accurate predictions indicated by the proximity of the target to the output of the crossover probability (p_c) 0.8, a population of 50, the number of generations 20000 and tournament size of 4 produces the testing RMSE 107.4769.

Keywords: prediction of daily stock price data, neural networks, feed forward neural network, genetic algorithm

1. PENDAHULUAN

Jaringan syaraf tiruan (JST) atau yang dikenal dengan istilah *Neural Network* (NN) merupakan sistem pemroses informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi. JST terdiri atas sejumlah elemen pemroses informasi yang disebut neuron. Neuron-neuron tersusun dalam lapisan dan mempunyai pola keterhubungan dalam dan antar lapisan yang disebut arsitektur jaringan. Model *Feed Forward Neural Networks* (FFNN) adalah model NN yang mempunyai arsitektur jaringan yang cukup sederhana dengan satu lapisan tersembunyi (*hidden layer*) dan dapat diterapkan untuk prediksi data *time series*.

Pada umumnya, FFNN dilatih menggunakan algoritma Backpropagation untuk mendapatkan bobot-bobotnya. Montana dan Davis (1993) telah menerangkan dalam penelitiannya bahwa Backpropagation dapat bekerja dengan baik pada masalah pelatihan sederhana tetapi kinerjanya akan menurun dan terjebak dalam minimal lokal apabila diterapkan pada data yang mempunyai kompleksitas yang besar. Solusi untuk masalah tersebut adalah melatih FFNN menggunakan Algoritma Genetika (AG).

AG adalah salah satu metode pendekatan untuk menentukan optimum global yang didasarkan pada Teori Darwin yaitu salah satu algoritma pencarian yang bertujuan untuk

menemukan solusi dari suatu masalah dengan membentuk sejumlah alternatif solusi yang disebut sebagai populasi. Dalam AG, terdapat empat parameter penting yang harus ditentukan oleh *user* agar AG menghasilkan solusi yang optimal. Parameter-parameter tersebut adalah probabilitas pindah silang (p_c), jumlah populasi, jumlah generasi, dan ukuran turnamen (k). Penelitian sebelumnya oleh Yuliandar (2012) telah membuktikan bahwa AG dapat digunakan dengan baik untuk melatih model FFNN yang diterapkan pada data *time series* harian nilai tukar (kurs) Dolar Australia (AUD) terhadap rupiah.

Prediksi data *time series* biasanya dilakukan dengan menggunakan metode konvensional seperti *Autoregressive Integrated Moving Average* (ARIMA). Metode ARIMA tersebut dikatakan konvensional karena kinerja model tersebut masih sangat dibatasi dengan adanya asumsi-asumsi seperti stasioneritas data, tidak ada autokorelasi residual, dan normalitas galat. Adanya asumsi-asumsi yang harus dipenuhi dalam menggunakan model ARIMA menunjukkan kelemahan model tersebut untuk digunakan sebagai alat prediksi terutama untuk data-data finansial seperti data harga saham.

Pada dasarnya kelemahan model ARIMA untuk prediksi data harga saham disebabkan oleh tidak sesuainya asumsi yang harus dipenuhi dengan karakteristik data saham yang mempunyai pola yang cenderung rumit. Kondisi inilah yang mendorong untuk mencoba menggunakan model FFNN dengan pelatihan AG untuk prediksi data harga saham, namun yang menjadi masalah adalah bagaimana memahami cara kerja pelatihan FFNN menggunakan AG, penentuan kombinasi probabilitas crossover (p_c), jumlah populasi, jumlah generasi, dan ukuran turnamen (k) pada AG untuk menghasilkan nilai prediksi yang mendekati nilai aktualnya. Salah satu pilihan yang mungkin adalah menggunakan teknik *trial-end-error* dengan melakukan percobaan untuk beberapa kombinasi dari keempat parameter tersebut.

Berdasarkan uraian diatas, maka dalam tulisan ini akan dilakukan Prediksi Data Harga Saham Harian Menggunakan *Feed Forward Neural Network* (FFNN) dengan Pelatihan Algoritma Genetika pada harga saham harian PT. XL Axiata Tbk.

2. TINJAUAN PUSTAKA

2.1 *Time Series*

Time series atau runtun waktu adalah himpunan observasi terurut dalam waktu (Wei, 1994). Metode *time series* adalah metode peramalan dengan menggunakan analisa pola hubungan antara variabel yang akan dipekirakan dengan dengan variabel waktu. Prediksi data *time series* biasanya dilakukan dengan menggunakan metode konvensional seperti *Autoregressive Integrated Moving Average* (ARIMA).

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan model ARMA nonstasioner yang telah *didifferencing* sehingga menjadi model stasioner. Ada beberapa model ARIMA yang dapat digunakan pada data *time series*, yaitu:

1) Model *Autoregressive* (AR)

Model *Autoregressive* (AR) dengan orde p dinotasikan dengan $AR(p)$. Bentuk umum model $AR(p)$ adalah:

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + e_t$$

dengan:

X_t = nilai variabel pada waktu ke- t

ϕ_i = koefisien *autoregressive*, $i : 1, 2, 3, \dots, p$

e_t = nilai galat pada waktu ke- t

p = order AR

2) Model *Moving Average* (MA)

Model *Moving Average* (MA) order q , dinotasikan menjadi MA(q). Secara umum, model MA(q) adalah:

$$X_t = e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}$$

dengan:

X_t = nilai variabel pada waktu ke- t

θ_i = parameter model *Moving Average* (MA), $i=1,2,3,\dots,q$

e_t = nilai galat pada waktu ke- t

e_{t-q} = nilai kesalahan pada saat $t-q$

q = order MA

3) Model *Autoregressive Moving Average* (ARMA)

Model *Autoregressive Moving Average* (ARMA) merupakan suatu gabungan dari model AR(p) dan MA(q). Bentuk umum model ARMA(p,q), yaitu:

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}$$

dengan:

X_t = nilai variabel pada waktu ke- t

ϕ_i = koefisien autoregressive ke- i , $i = 1,2,3,\dots,p$

p = order AR

q = order MA

θ_i = parameter model MA ke- i , $i = 1,2,3,\dots,q$

e_t = nilai galat pada waktu ke- t

2.2 Algoritma Genetika

Fadlisyah, *et.al* (2009) menerangkan bahwa Algoritma Genetika (AG) bekerja dari populasi yang merupakan himpunan solusi yang dihasilkan secara acak. Setiap anggota himpunan yang merepresentasikan satu solusi masalah dinamakan individu atau kromosom. Sebuah kromosom berisi sejumlah gen, yang mengkodekan informasi yang disimpan di dalam kromosom. Sebuah kromosom berkembang biak melalui berbagai iterasi yang berulang-ulang yang disebut generasi. Pada setiap generasi, kromosom-kromosom yang dihasilkan akan dievaluasi menggunakan suatu pengukuran yang disebut *fitness*. Pada AG, *fitness* biasanya dapat berupa fungsi objektif dari masalah yang akan dioptimalisasi.

Untuk menghasilkan suatu generasi baru, dilakukan penyeleksian berdasarkan nilai *fitness* untuk menentukan kromosom orang tua (*parent*) yang akan menghasilkan kromosom anak (*offspring*) yang dibentuk dengan menggabungkan dua buah kromosom orang tua yang terpilih menggunakan operator kawin silang (*crossover*) dan memodifikasi sebuah kromosom menggunakan operator mutasi. Setelah melalui beberapa generasi maka algoritma ini akan konvergen ke kromosom terbaik (Kusumadewi, 2003).

Ada beberapa komponen utama yang ada dalam AG tetapi banyak variasi metode yang diusulkan pada masing-masing komponen tersebut. Prosedur inisialisasi adalah membangkitkan sejumlah individu secara acak atau melalui prosedur tertentu sebagai populasi awal. Ukuran populasi tergantung pada masalah yang akan dipecahkan dan jenis operator genetika yang akan diimplementasikan (Kusumadewi, 2003).

Dalam AG, Gen-gen yang diinisialisasi dalam Algoritma Genetika merupakan estimasi nilai mula-mula yang mengandung informasi dalam bentuk kode-kode tertentu. Satu gen mewakili satu parameter yang akan diestimasi nilainya agar suatu fungsi optimal. Suyanto (2005) menjelaskan bahwa, dengan menggunakan suatu interval tertentu, jika batas bawah r_b dan batas atas r_a , kode suatu gen g dan kode bit-bit yang menyusun suatu gen g_1, g_2, \dots, g_n maka pendekodean biner dapat dilakukan dengan cara sebagai berikut:

Binary encoding

$$x = r_b + (r_a - r_b)(g_1 \times 2^{-1} + g_2 \times 2^{-2} + \dots + g_n \times 2^{-n})$$

Suatu individu dievaluasi berdasarkan suatu fungsi tertentu sebagai ukuran performansinya atau yang disebut nilai *fitness*. Di dalam evolusi alam, individu yang bernilai *fitness* tinggi yang akan bertahan hidup, sedangkan individu yang bernilai *fitness* rendah akan mati (Kusumadewi, 2003). Adanya proses crossover dan mutasi, terdapat risiko hilangnya suatu individu bernilai *fitness* tertinggi karena proses seleksi dilakukan secara random sehingga tidak ada jaminan bahwa suatu individu bernilai *fitness* tertinggi akan selalu terpilih. Untuk menjaga agar individu bernilai *fitness* tertinggi tersebut tidak hilang selama evolusi, maka perlu dibuat satu atau beberapa salinan. Prosedur ini dikenal sebagai elitisme (Suyanto, 2005). Prosedur *Linear Fitness Ranking* (LFR) diperlukan untuk menghindari kecenderungan untuk konvergen pada optimal lokal dapat dikurangi dengan menggunakan persamaan:

$$f(i) = f_{max} - (f_{max} - f_{min}) \left(\frac{R(i)-1}{N-1} \right)$$

dengan demikian diperoleh nilai *fitness* yang berada dalam interval $[f_{min}, f_{max}]$ (Suyanto, 2005).

Kusumadewi (2003) menjelaskan bahwa dari individu-individu yang ada dalam suatu populasi, perlu dipilih individu-individu terbaik yang dapat melakukan perkawinan untuk menghasilkan individu baru. Seleksi ini bertujuan untuk memberikan kesempatan reproduksi yang lebih besar bagi anggota populasi yang paling *fit*. Ada beberapa metode seleksi dalam AG. Pada seleksi alami yang terjadi di dunia nyata, beberapa individu (biasanya individu jantan) berkompetisi dalam sebuah kelompok kecil sampai tersisa hanya satu individu pemenang. Individu pemenang inilah yang bisa kawin (pindah silang). Sebuah metode yang disebut *tournament selection* mencoba mengadopsi karakteristik alami ini. Dalam bentuk paling sederhana, metode ini mengambil dua kromosom secara random dan kemudian menyeleksi salah satu yang bernilai *fitness* tertinggi untuk menjadi orang tua pertama. Cara yang sama dilakukan lagi untuk mendapatkan orang tua yang kedua. Metode *tournament selection* yang lebih rumit adalah dengan mengambil k kromosom secara random. Kemudian kromosom bernilai *fitness* tertinggi dipilih sebagai orang tua pertama jika bilangan random yang dibangkitkan kurang dari suatu nilai batas yang ditentukan p_k dalam interval $[0,1]$. Pemilihan orang tua akan dilakukan secara random dari $k-1$ kromosom yang ada jika bilangan random yang dibangkitkan lebih dari atau sama dengan p_k .

Terdapat dua operator genetika yaitu *crossover* dan mutasi. *Crossover* bertujuan menambah keanekaragaman string dalam satu populasi dengan penyilangan antar string yang diperoleh dari reproduksi sebelumnya. Proses *crossover* dilakukan pada setiap individu dengan probabilitas *crossover* (p_c) yang ditentukan secara random dalam rentang $[0, 1]$. Artinya, kawin silang bisa dilakukan hanya jika suatu bilangan random $[0, 1]$ yang dibangkitkan kurang dari p_c yang ditentukan. Sedangkan, Mutasi merupakan proses untuk mengubah nilai dari satu atau beberapa gen dalam suatu kromosom. Proses mutasi terjadi jika bilangan random yang dibangkitkan kurang dari probabilitas mutasi p_m yang ditentukan maka ubah gen tersebut menjadi nilai kebalikannya (dalam *binary encoding*, 0 diubah 1 dan 1 diubah 0).

2.3 Neural Network

Haykin (1994) menyatakan bahwa Jaringan Syaraf Tiruan (JST) atau *Neural Network* (NN) adalah sebuah mesin yang dirancang untuk memodelkan cara kerja otak manusia dalam mengerjakan fungsi atau tugas-tugas tertentu. Mesin ini memiliki kemampuan menyimpan pengetahuan berdasarkan pengalaman dan menjadikan simpanan pengetahuan yang dimiliki menjadi bermanfaat. NN memiliki dua tahap pemrosesan informasi, yaitu tahap pelatihan dan tahap pengujian. Warsito (2009) menjelaskan bahwa tahap pelatihan dimulai dengan memasukkan pola-pola belajar (data latih) ke dalam jaringan. Dengan menggunakan pola-pola ini, jaringan akan mengubah-ubah bobot yang menjadi penghubung antara node.

Sedangkan tahap pengujian dilakukan terhadap suatu pola masukan yang belum pernah dilatihkan sebelumnya (data uji) dengan menggunakan bobot hasil tahap pelatihan. Diharapkan bobot-bobot hasil pelatihan yang sudah menghasilkan *error* minimal juga akan memberikan *error* yang kecil pada tahap pengujian.

Dalam NN terdapat susunan dari neuron-neuron dalam lapisan yang mempunyai pola keterhubungannya dalam dan antar lapisan yang disebut dengan arsitektur jaringan. NN biasanya terdiri dari lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan output (*output layer*). *Feed Forward Neural Networks* (FFNN) adalah satu model NN yang mempunyai arsitektur jaringan yang cukup sederhana dengan satu lapisan tersembunyi (*hidden layer*) dan dapat diterapkan untuk prediksi *time series*. Pada pemodelan FFNN untuk data *time series*, input model adalah data masa lalu ($X_{t-1}, X_{t-2}, \dots, X_{t-p}$) dan targetnya adalah data masa kini X_t (Warsito, 2009).

Bentuk umum model FFNN untuk data *time series* dituliskan dalam persamaan berikut :

$$X_t = \psi_o \left\{ w_{bo} + \sum_{j=1}^H w_{jo} \psi_j \left(w_{bj} + \sum_{i=1}^p w_{ij} X_{t-i} \right) \right\}$$

dengan

ψ_o : fungsi aktivasi yang digunakan pada lapisan output

ψ_j : fungsi aktivasi yang digunakan pada lapisan tersembunyi

w_{ij} : bobot neuron ke-i pada lapisan input menuju neuron ke-j pada lapisan tersembunyi

w_{bj} : bobot bias pada lapisan input menuju neuron ke-j pada lapisan tersembunyi

w_{jo} : bobot neuron ke-j pada lapisan tersembunyi menuju lapisan output

w_{bo} : bobot bias pada lapisan tersembunyi menuju lapisan output

3. METODOLOGI PENELITIAN

3.1 Metode Pengumpulan Data

Data yang digunakan dalam tulisan ini adalah data sekunder, yaitu data saham harian PT XL Axiata Tbk periode 3 Januari 2011 sampai dengan 28 Maret 2014 yang terdiri dari 829 data saham harian yang tercatat.

3.2 Teknik Pengolahan Data

Model *neural network* yang akan digunakan secara khusus dalam tulisan ini adalah model *Feed Forward Neural Networks* (FFNN). Arsitektur jaringan FFNN untuk prediksi data harga saham harian terdiri dari p unit input dari $X_{t-1}, X_{t-2}, \dots, X_{t-p}$ dengan satu unit *hidden layer* yang terdiri dari H neuron, 1 unit output dan bias.

Setelah terbentuk arsitektur jaringan pada FFNN maka langkah selanjutnya adalah mencari estimasi dari bobot atau parameter pada FFNN dengan menggunakan Algoritma Genetika (AG). Prosedur AG sebagai metode pelatihan dalam FFNN dilakukan dengan menginisialisasi populasi sebagai ruang solusi yang berisi kromosom-kromosom. Setiap kromosom merepresentasikan beberapa gen dimana ketika didekodekan akan menghasilkan bobot atau parameter jaringan. Selanjutnya kromosom-kromosom tersebut akan dievaluasi dengan menggunakan fungsi objektif tertentu untuk mendapatkan nilai *fitness* yang merupakan skala pengukuran dalam AG. Untuk mendapatkan generasi baru dilakukan penyeleksian berdasarkan nilai *fitness* dengan metode seleksi tertentu serta menggunakan operator genetika kawin silang (*crossover*) dan mutasi. Setelah melalui beberapa generasi yang ditentukan, maka AG akan konvergen ke kromosom terbaik dan diperoleh solusi berupa nilai bobot atau parameter yang optimum.

4. HASIL DAN PEMBAHASAN

Pada pemodelan *time series*, data masa kini dipengaruhi oleh data masa lalu sehingga dalam hal ini input data pada model FFNN adalah data masa lalu (lag time) dan targetnya adalah data masa kini, sebagaimana terminologi autoregressif pada metode ARIMA Box-Jenkins (Warsito, 2009). Identifikasi lag sebagai komponen input didasarkan pada lag-lag yang memiliki nilai PACF terbesar. Hal ini dikarenakan karakteristik persamaan model FFNN memiliki kesamaan dengan model AR. Berdasarkan identifikasi lag diperoleh 4 variabel lag yang akan dijadikan sebagai komponen input, yaitu lag 1, 4, 11, dan 27 atau dapat dikatakan bahwa X_t dipengaruhi oleh X_{t-1} , X_{t-4} , X_{t-11} dan X_{t-27} sehingga hanya terdapat 802 data yang akan dilatih dengan jaringan FFNN.

Dalam penulisan tugas akhir ini masalah dibatasi pada jumlah unit *hidden layer* sama dengan jumlah unit pada *input layer*, maka arsitektur jaringan yang terbentuk terdiri dari 4 unit input variabel yang dianggap berpengaruh, 1 *hidden layer* yang terdiri dari 4 neuron, 1 neuron pada *output layer* dan bias. Sedangkan fungsi aktivasi yang digunakan pada *hidden layer* menuju ke *output layer* adalah sigmoid biner (sigmoid logistik) 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 25 unit yang terdiri dari 16 bobot neuron untuk memberikan sinyal input pada *hidden layer* (w_{ij}), 4 bobot bias untuk *hidden layer* (w_{bj}), 4 bobot neuron untuk menghasilkan *output layer* (w_{jo}) dan 1 bobot bias untuk *output layer* (w_{bo}).

Proses pelatihan dan pengujian pada data harga saham harian PT. XL Axiata Tbk dilakukan menggunakan Algoritma Genetika (AG) dengan seleksi turnamen. Observasi untuk menghasilkan nilai prediksi yang mendekati nilai aktualnya dilakukan dengan cara uji coba 64 kombinasi yang terdiri dari 4 nilai p_c , 2 jumlah populasi, 2 jumlah generasi, dan 4 ukuran turnamen yang berbeda-beda. Hasilnya adalah sebagai berikut :

Tabel 1. Hasil Pelatihan dan Pengujian dengan 64 Kombinasi Probabilitas Pindah Silang (p_c), Jumlah Populasi, Jumlah Generasi, dan Ukuran Turnamen (k)


No	Pc	Populasi	Generasi	K	Training		Testing	
					MSE	RMSE	MSE	RMSE
1	0,2	50	10000	4	1.72E+04	131.296	4.59E+04	214.13
2				5	1.74E+04	131.772	7.78E+04	279.0075
3				6	1.74E+04	131.7511	2.10E+04	145.0355
4				7	1.74E+04	131.7778	1.48E+04	121.5253
5			20000	4	1.72E+04	131.3325	1.34E+04	115.6628
6				5	1.73E+04	131.4824	1.23E+04	111.0793
7				6	1.73E+04	131.4243	2.15E+05	464.0757
8				7	1.73E+04	131.514	1.39E+04	117.9621
9		100	10000	4	1.73E+04	131.6695	2.66E+04	163.0969
10				5	1.72E+04	131.2851	2.66E+04	163.0773
11				6	1.73E+04	131.5198	1.25E+05	354.0655
12				7	1.72E+04	131.3265	9.91E+04	314.8344
13			20000	4	1.73E+04	131.5463	3.44E+04	185.5028
14				5	1.72E+04	131.137	2.83E+04	168.2931
15				6	1.73E+04	131.4566	1.27E+05	356.0379
16				7	2.91E+05	539.3018	4.14E+05	643.4124

No	Pc	Populasi	Generasi	K	Training		Testing	
					MSE	RMSE	MSE	RMSE
17	0,4	50	10000	4	1.73E+04	131.5463	2.49E+04	157.8581
18				5	1.73E+04	131.4361	4.10E+04	202.5749
19				6	1.74E+04	131.8051	1.18E+04	108.4372
20				7	1.73E+04	131.6935	3.47E+04	186.3639
21			20000	4	1.73E+04	131.4346	5.59E+04	236.501
22				5	1.74E+04	131.7189	5.60E+05	748.4634
23				6	1.71E+04	130.7098	1.24E+04	111.3325
24				7	1.73E+04	131.6461	1.86E+04	136.5139
25		100	10000	4	1.72E+04	131.185	2.64E+05	513.908
26				5	1.74E+04	131.9294	2.85E+04	168.8525
27				6	1.73E+04	131.484	1.18E+04	108.4472
28				7	1.73E+04	131.4375	1.18E+04	108.5773
29			20000	4	1.72E+04	131.2148	1.17E+04	108.0496
30				5	1.73E+04	131.4482	1.94E+04	139.4598
31				6	1.73E+04	131.5377	1.29E+04	113.3741
32				7	1.73E+04	131.4923	1.18E+04	108.794
33	0,6	50	10000	4	1.74E+04	131.7938	2.81E+04	167.6539
34				5	1.72E+04	131.2706	1.83E+04	135.164
35				6	1.73E+04	131.679	3.31E+04	181.9887
36				7	1.73E+04	131.5529	1.22E+04	110.4154
37			20000	4	1.74E+04	131.7594	2.10E+05	458.5214
38				5	1.73E+04	131.3487	1.19E+04	109.0845
39				6	1.73E+04	131.6791	1.29E+04	113.3829
40				7	1.73E+04	131.6505	1.31E+04	114.2692
41		100	10000	4	1.73E+04	131.5866	8.11E+04	284.8625
42				5	1.73E+04	131.4989	5.12E+04	226.2278
43				6	1.73E+04	131.61	2.54E+04	159.2918
44				7	1.73E+04	131.3392	1.93E+04	138.7636
45			20000	4	1.72E+04	131.1788	1.18E+04	108.6818
46				5	1.73E+04	131.5712	2.91E+05	539.8884
47				6	1.70E+04	130.3553	1.47E+04	121.0936
48				7	1.73E+04	131.4679	1.18E+04	108.7924
49	0,8	50	10000	4	1.74E+04	131.7912	1.16E+04	107.6808
50				5	1.77E+04	132.9111	1.29E+04	113.6225
51				6	1.75E+04	132.4656	1.86E+04	136.2042
52				7	1.76E+04	132.5488	2.05E+04	143.2957
53			20000	4	1.73E+04	131.6281	1.16E+04	107.4769
54				5	1.73E+04	131.6096	1.1663E+04	107.995
55				6	1.72E+04	131.2461	2.41E+04	155.0894
56		100	10000	7	1.73E+04	131.6999	1.19E+04	109.1045
57				4	1.72E+04	131.0438	1.72E+04	131.1489
58				5	1.73E+04	131.6712	1.19E+04	109.0131

No	Pc	Populasi	Generasi	K	Training		Testing	
					MSE	RMSE	MSE	RMSE
59				6	1.73E+04	131.5671	4.55E+04	213.2677
60				7	1.72E+04	131.0709	8.30E+04	288.1691
61			20000	4	1.73E+04	131.5219	3.50E+04	187.2027
62				5	1.73E+04	131.5481	1.17E+04	108.2187
63				6	1.73E+04	131.6539	1.16E+05	340.5168
64				7	1.73E+04	131.6155	9.12E+04	302.0265

Untuk memilih model yang terbaik adalah dengan melihat nilai RMSE terkecil pada pengujian. Terlihat bahwa pada kombinasi nomor 53 dengan probabilitas crossover (p_c) = 0.8, jumlah populasi 50, jumlah generasi 20000, dan ukuran turnamen (k) = 4 menghasilkan error pengujian paling kecil dibandingkan kombinasi yang lainnya.

Berikut ini ditampilkan performansi pelatihan AG dengan kombinasi probabilitas crossover (p_c) = 0.8, jumlah populasi 50, jumlah generasi 20000, dan ukuran turnamen (k) = 4:



Gambar 1. Performansi Pelatihan AG dengan Kombinasi Nomor 53

Berdasarkan gambar 1 terlihat bahwa proses AG dihentikan setelah mencapai generasi ke 20000. Selain itu nilai fitness yang dihasilkan telah konvergen dan mencapai optimum global yaitu dengan nilai fitness terbaik sebesar 0.03191 dan rata-rata nilai fitness sebesar 0.03191. Sedangkan nilai bobot atau parameter yang optimum ditampilkan dalam tabel berikut :

Tabel 2. Bobot atau Parameter Optimum Hasil Pelatihan

W_{bj}	W_{ij}				W_{bo}	W_{jo}
0.8442	-0.9993	0.9912	0.952	3.2129	0.1299	-0.8479
-0.9768	0.2831	0.084	0.4321	-0.1586		0.263
-0.9928	0.009	0.9023	0.7825	-1.4206		0.8848
-0.8998	0.0673	0.345	-0.0818	0.1362		0.6151

Dari bobot atau parameter yang telah optimum hasil pelatihan diatas maka model FFNN untuk data harga saham harian PT. XL Axiata Tbk dapat dituliskan sebagai berikut :

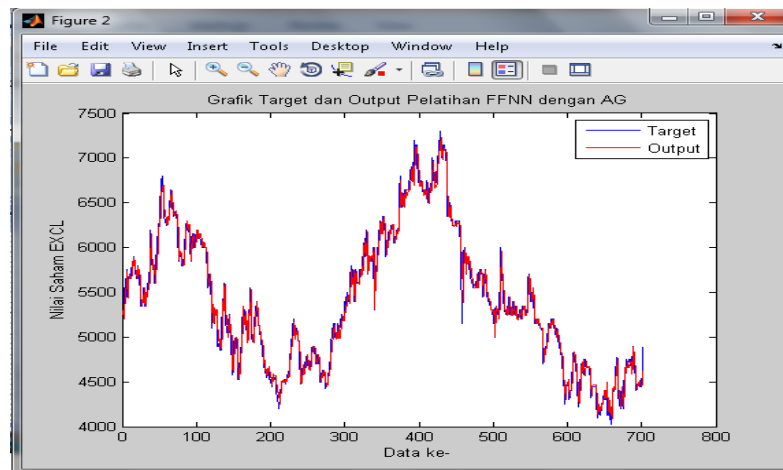
$$\hat{X}_t = 0.1299 + \frac{-0.8479}{1 + \exp\left(\frac{-(0.8442 - 0.9993X_{t-1} + 0.2831X_{t-4} + 0.009X_{t-11} + 0.0673X_{t-27})}{0.263}\right)}$$

$$+ \frac{1}{1 + \exp\left(\frac{-(-0.9768 + 0.9912X_{t-1} + 0.084X_{t-4} + 0.9023X_{t-11} + 0.345X_{t-27})}{0.8848}\right)}$$

$$+ \frac{1}{1 + \exp\left(\frac{-(-0.9928 + 0.952X_{t-1} + 0.4321X_{t-4} + 0.7825X_{t-11} - 0.0818X_{t-27})}{0.6151}\right)}$$

$$+ \frac{1}{1 + \exp\left(\frac{-(-0.8998 + 3.2129X_{t-1} - 0.1586X_{t-4} - 1.4206X_{t-11} + 0.1362X_{t-27})}{0.6151}\right)}$$

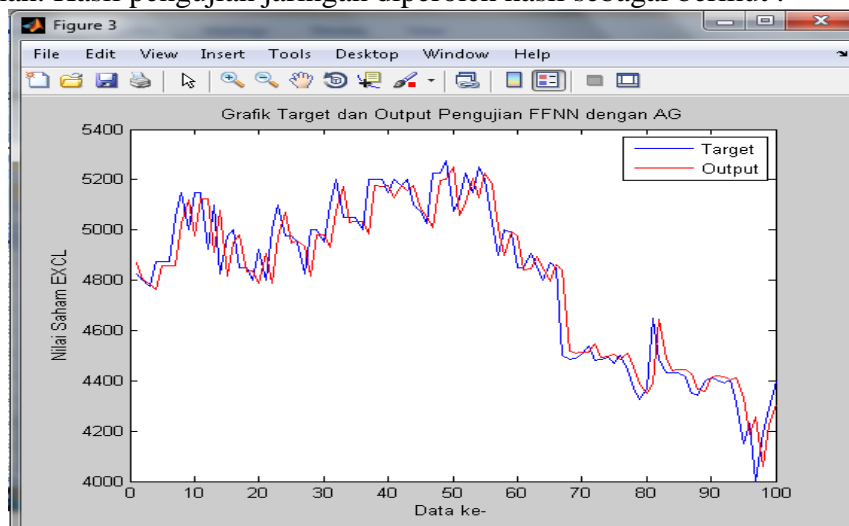
Berdasarkan model FFNN tersebut maka diperoleh hasil pelatihan jaringan sebagai berikut :



Gambar 2. Perbandingan Target dan Output Pelatihan FFNN dengan AG

Berdasarkan Gambar 2 terlihat bahwa pelatihan jaringan telah memberikan hasil prediksi yang cukup akurat yang ditunjukkan oleh kedekatan target (garis berwarna biru) dengan output (garis berwarna merah).

Data yang digunakan pada tahap pengujian ini sebanyak 100 data harga saham harian. Pengujian dilakukan dengan menggunakan bobot atau parameter yang sudah optimum hasil dari tahap pelatihan. Hasil pengujian jaringan diperoleh hasil sebagai berikut :



Gambar 3. Perbandingan Target dan Output Pengujian FFNN dengan AG

Berdasarkan Gambar 3 terlihat bahwa pengujian jaringan telah memberikan hasil prediksi yang cukup akurat yang ditunjukkan oleh kedekatan target (titik berwarna biru) dengan output (titik berwarna merah). Sehingga dapat dikatakan bahwa model FFNN yang telah dihasilkan

dapat digunakan dengan baik untuk memprediksi data harga saham harian PT. XL Axiata Tbk.

5. KESIMPULAN

Berdasarkan analisis dan pembahasan yang telah dilakukan dapat diambil kesimpulan sebagai berikut:

1. Cara kerja pelatihan FFNN dengan menggunakan Algoritma Genetika untuk prediksi data harga saham harian PT. XL Axiata Tbk adalah dengan membentuk arsitektur jaringan pada FFNN, kemudian setelah arsitektur jaringan terbentuk langkah selanjutnya adalah mencari estimasi bobot atau parameter dengan menggunakan Algoritma Genetika (AG). Prosedur AG sebagai metode pelatihan pada FFNN dilakukan dengan menginisialisasi populasi, kemudian dekodekan kromosom, mengevaluasi individu dan elitisme. Apabila generasi maksimum belum tercapai akan dilakukan *Linier Fitness Ranking* (LFR), seleksi, crossover, mutasi, penggantian populasi, kemudian dilakukan evaluasi individu dan elitisme kembali hingga generasi maksimum yang telah ditentukan tercapai.
2. Setelah dilakukan uji coba sebanyak 64 kali untuk kombinasi probabilitas pindah silang, jumlah populasi, jumlah generasi, dan ukuran turnamen yang berbeda-beda diperoleh kesimpulan bahwa kombinasi nomor 53 dengan probabilitas pindah silang 0.8, jumlah populasi 50, jumlah generasi 20000 dan ukuran turnamen 4 menghasilkan nilai prediksi yang mendekati nilai aktualnya. Hal ini dibuktikan dengan nilai RMSE pengujian yang paling kecil dibandingkan dengan kombinasi yang lain yaitu sebesar 107.4769.

6. DAFTAR PUSTAKA

- Desiani dan Arhami. 2006. *Konsep Kecerdasan Buatan*. Andi Offset. Yogyakarta.
- Fadliyah, Arnawan dan Faisal. 2009. *Algoritma Genetik*. Graha Ilmu. Yogyakarta.
- Fausett, L. 1994. *Fundamental of Neural Network : Architecture, Algorithm and Application*. New Jersey. Prentice-Hall.
- Haykin, S. 1994. *Neural Networks: A Comprehensive Foundation*. Macmillan Publishing Company, New York.
- Kusumadewi, S. 2003. *Artificial Intelligence (Teknik dan Aplikasinya)*. Graha Ilmu. Yogyakarta.
- Makridakis, Wheelwright dan McGee. 1995. *Metode dan Aplikasi Peramalan*. Erlangga. Jakarta.
- Montana, D.J, and Davis, L. 1993. *Training Feedforward Neural Networks Using Genetic Algorithms*. BBN Systems and Technologies Corp. 10 Moution St. Cambridge, MA.
- Pandjaitan, L.W. 2007. *Dasar-Dasar Komputasi Cerdas*. Andi Offset. Yogyakarta.
- Siang, J.J. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan MATLAB*. Andi Offset. Yogyakarta.
- Suyanto. 2005. *Algoritma Genetika dalam MATLAB*. Andi Offset. Yogyakarta.
- Warsito, B. 2009. *Kapita Selekt Statistika Neural Network*. BP Universitas Diponegoro. Semarang.
- Wei, W.W.S. 1994. *Time Series Analysis : Univariate and Multivariate Methods*. Addison-Wesley Publishing Company Inc. Canada.
- Yuliandar, D. 2012. Pelatihan Feed Forward Neural Network Menggunakan Algoritma Genetika dengan Seleksi Turnamen untuk Data Time Series. *Jurnal Gaussian Volume 1 Nomor 1 Universitas Diponegoro*. Semarang.
- www.finance.yahoo.com (diakses pada tanggal 31 Maret 2014).