

PERAMALAN HARGA SAHAM BERDASARKAN JARINGAN SYARAF FUZZY ELMAN RECURRENT DENGAN OPTIMASI EVOLUTIF

STOCK PRICE FORECASTING BASED ON FUZZY ELMAN RECURRENT NEURAL NETWORKS WITH EVOLUTIVE OPTIMIZATION

Rosita Kusumawati¹, Dhoriva Urwatul Wutsqa², Retno Subekti³

^{1, 2, 3}Program Studi Matematika, Jurusan Pendidikan Matematika, FMIPA, Universitas Negeri Yogyakarta
*email: rosita_kusumawati@uny.ac.id

Abstrak

Analisis runtun waktu telah banyak digunakan untuk menentukan harga saham masa depan. Analisis dan pemodelan runtun waktu keuangan merupakan tugas penting untuk membantu investor dalam mengambil keputusan. Meskipun demikian, prediksi harga dengan menggunakan runtun waktu tidak sederhana dan memerlukan analisa yang mendalam. Selain itu, di lingkungan yang dinamis seperti pasar saham, non linieritas dari runtun waktu adalah karakteristik yang diucapkan, dan ini segera mempengaruhi keefektifan ramalan harga saham. Dengan demikian, makalah ini bertujuan untuk mengusulkan sebuah metodologi yang meramalkan harga saham bulanan perusahaan Indonesia, yang diperdagangkan di Bursa Efek Jakarta. Kami mengusulkan jaringan syaraf Fuzzy Elman Recurrent untuk meramalkan harga saham dan algoritma genetika untuk mengoptimalkan bobot model. Prediksi kinerja dievaluasi dengan menggunakan perhitungan Mean Absolute Persentase Persentase (MAPE). Makalah ini menyimpulkan bahwa metode yang diusulkan mengoptimalkan peramalan harga.

Kata kunci: peramalan harga saham, runtun waktu, fuzzy elman recurrent neural network

Abstract

Time series forecasting has been widely used to determine future prices of stocks, and the analysis and modeling of finance time series is an important task for guiding investors' decisions and trades. Nonetheless, the prediction of prices by means of a time series is not trivial and it requires a thorough analysis. In addition, in a dynamic environment such as the stock market, the non-linearity of the time series is a pronounced characteristic, and this immediately affects the efficacy of stock price forecasts. Thus, this paper aims at proposing a methodology that forecasts the monthly stock prices of four Indonesian companies, which are traded in the Jakarta Stock Exchange. We propose a Fuzzy Elman Recurrent neural network for forecasting stock prices and we use a genetic algorithm to optimize the weight of the models. Performances prediction are evaluated by means Mean Absolute Percentage Error (MAPE) calculations. This paper concludes that the proposed method optimizes the prices forecasting.

Keywords: stock price forecasting, time series, fuzzy elman recurrent neural network

Pendahuluan

Analisis runtun waktu adalah suatu metode kuantitatif untuk menentukan pola data masa lalu yang telah dikumpulkan secara teratur. Banyak bidang menggunakannya untuk membantu perencanaan dan pengambilan keputusan, salah satunya bidang keuangan. Pelaku disektor keuangan menggunakan model-model peramalan dalam analisis runtun waktu untuk mendukung pengambilan keputusan investasi. Model peramalan mengalami perkembangan dimulai dari model-model regresif seperti *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA) dan model *Autoregressive Moving Average Moving Average* (ARIMA). Pengembangan model-model peramalan dengan tingkat akurasi yang tinggi terus dikembangkan.

Pallit dalam bukunya mengumpulkan beberapa metode terbaik seperti model regresif, jaringan syaraf tiruan, model fuzzy [1].

Pola data runtun waktu pada beberapa sektor menunjukkan perilaku yang tidak liner dan kompleks. Sehingga model peramalan linear tidak cocok untuk menganalisis data dengan kondisi tersebut. Model jaringan syaraf tiruan dianggap pendekatan yang berguna untuk mengatasi masalah tersebut. [2] Model jaringan syaraf tiruan dapat dibedakan menjadi 2 jenis yaitu Feedforward Neural Network (FFNN) dan Recurrent Neural Network (RNN) [3]. RNN merupakan jaringan perkembangan dari FFNN yang mengakomodasi output jaringan untuk menjadi input jaringan dalam rangka menghasilkan output jaringan berikutnya [4]. RNN sendiri terbagi menjadi dua kelas yaitu

Elman Recurrent Neural Network (ERNN) dan Hopfield Neural Network (HNN). Elman Recurrent Neural Network adalah jaringan yang menggunakan koneksi feedforward pada neuron tersembunyi menuju neuron input sedangkan Hopfield Neural Network adalah jaringan yang menggunakan koneksi bidirectional dengan bobot simetris sehingga tidak ada perbedaan antara input dan output neuron.

Model jaringan syaraf tiruan (JST) memiliki kelemahan konvergensi yang lambat dan stagnasi minimum lokal yang mudah. Berbagai tehnik diteliti untuk mengatasi masalah tersebut. Salah cara yang biasa digunakan adalah algoritma genetika (AG). AG banyak digunakan untuk mengoptimalkan model dalam peramalan waktu untuk konsumsi energi [5, 6], untuk nilai tukar rupiah terhadap dollar [7], serta indeks harga saham gabungan [8]. Cara lain yang ditempuh untuk mengatasi kelemahan dari model JST adalah dengan mengintegrasikan logika fuzzy ke dalam model, sehingga diperoleh model pengembangan yaitu Fuzzy Elman Recurrent Neural Network (FERNN) dengan tingkat akurasi peramalan yang cukup baik [4].

Berdasarkan kelebihan FERNN dan optimasi algoritma genetika serta kepentingan melakukan peramalan harga sahan di Indonesia, tim peneliti akan membahas mengenai *Fuzzy Elman Recurrent Neural Network* (FERNN) untuk Peramalan saham di Indonesia dengan optimasi algoritma genetika. Artikel hasil penelitian ini akan terdiri dari dua bagian yaitu bagian pertama yang berisi kepentingan mempelajari dan penjelasan teoritis model dasar FERNN. Dan bagian kedua yang berisi penerapan model pada data saham Indonesia.


Fuzzy Elman Recurrent Neural Network

Langkah awal prosedur pembentukan model FERNN dengan melihat lag yang signifikan dari plot *autokorelasi*, yaitu ditentukan oleh banyaknya *autokorelasi lag* yang keluar yang melebihi batas garis signifikansi pada plot ACF. Pembagian data menjadi dua yaitu 75% data *training* dan 25% data *testing*. *Fuzzifikasi* dilakukan dengan menggunakan fungsi keanggotaan segitiga dan kurva S pertumbuhan dengan persamaannya berturut-turut:

$$\mu(x) = \begin{cases} 0 & x \leq a \\ \frac{x-a}{b-a} & a < x \leq b \\ \frac{c-x}{c-b} & b < x \leq c \\ 1 & x \geq c \end{cases} \quad (1)$$

$$\mu(x) = \begin{cases} 0 & x \leq \alpha \\ 2\left(\frac{x-\alpha}{\gamma-\alpha}\right)^2 & \alpha \leq x \leq \beta \\ 1 - 2\left(\frac{\gamma-x}{\gamma-\alpha}\right)^2 & \beta \leq x \leq \gamma \\ 1 & x \geq \gamma \end{cases} \quad (2)$$

Data yang telah difuzzifikasi kemudian digunakan untuk pembentukan model. Pembentukan model terbaik dilakukan dengan menentukan banyak neuron pada lapisan tersembunyi menggunakan algoritma pembelajaran *backpropagation* dan eliminasi input secara *trial* dan *error* sehingga menghasilkan arsitektur model FERNN. Arsitektur model FERNN terlihat pada Gambar 1 berikut:



Gambar 1. Arsitektur FERNN

Setiap neuron antar lapisan pada FERNN dihubungkan oleh bobot-bobot yang bersesuaian. Untuk menghitung keluaran pada lapisan tersembunyi dan lapisan tambahan menggunakan fungsi aktivasi *sigmoid bipolar* dan keluaran pada lapisan *output* digunakan fungsi aktivasi *linear*. Model FERNN berdasarkan gambar 1 dan fungsi aktivasi, secara matematis dapat dirumuskan dengan persamaan:

$$Y_{ts} = \sum_{k=1}^m v_k(s) \frac{1 - \exp\left(-\left(\sum_{i=1}^n \sum_{k=1}^m x_i w_{ik}(s) + \sum_{j=1}^m \sum_{k=1}^m u_{kj} w_{jk} + b_k\right)\right)}{1 + \exp\left(-\left(\sum_{i=1}^n \sum_{k=1}^m x_i w_{ik}(s) + \sum_{j=1}^m \sum_{k=1}^m u_{kj} w_{jk} + b_k\right)\right)} + b_{0,s} \quad (3)$$

dengan \$Y_{ts}\$ adalah nilai prediksi ke-t pada FERNN dan, s adalah banyak himpunan *fuzzy*, \$x_i\$ adalah variabel *input* pada FERNN data *training*, \$w_{ik}(s)\$ adalah bobot lapisan *input* ke lapisan tersembunyi, \$w_{jk}\$ adalah bobot lapisan tambahan ke lapisan tersembunyi, \$b_k\$ adalah bobot bias lapisan *input* ke lapisan tersembunyi, \$v_k(s)\$ adalah bobot lapisan lapisan tersembunyi ke lapisan *output*, dan \$b_{0,s}\$ adalah bobot bias lapisan input tersembunyi ke lapisan *output*. Bobot-bobot tersebut menghasilkan nilai MAPE. Model terbaik menghasilkan nilai MAPE yang kecil.

Nilai MAPE yaitu persentase nilai rata-rata Absolute Error dari kesalahan peramalan dan nilai MSE yaitu jumlah kuadrat selisih dari kesalahan prediksi dibagi dengan banyak pengamatan yang dirumuskan sebagai berikut [9]:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|e_t|}{Y_t} \times 100\% \quad (4)$$

$$MSE = \sum_{t=1}^n \frac{e_t^2}{n} \quad (5)$$

dengan e_t adalah *error* peramalan pada waktu ke- t , Y_t adalah nilai aktual data ke- t dan n adalah banyaknya pengamatan. Nilai *output* yang diperoleh dari estimasi *input* dan bobot menggunakan model pada persamaan (3) masih berupa derajat keanggotaan himpunan *fuzzy*. Proses *defuzzifikasi* dilakukan terhadap bilangan-bilangan *fuzzy* yang diperoleh tersebut untuk memperoleh nilai dalam himpunan *crisp*.

Algoritma Genetika

Algoritma genetika merupakan sebuah metode untuk menyelesaikan masalah optimasi dengan memanfaatkan proses seleksi alamiah yang dikenal dengan proses evolusi biologis. Dalam proses evolusi hanya individu-individu yang kuat yang mampu bertahan. Konsep dasar algoritma genetika untuk memperoleh individu terbaik sebagai solusi dari permasalahan melalui proses seleksi, *crossover*, dan mutasi. Pada penelitian ini yang akan dioptimasi adalah bobot akhir dari model FERNN. Bobot dikatakan optimasi jika menghasilkan *error* yang lebih kecil dibanding *error* dari FERNN tanpa optimasi dengan algoritma genetika. Error pada penelitian ini dipresentasikan dengan nilai MAPE. Nilai MAPE diperoleh dengan persamaan (4). Prosedur penerapan algoritma genetika dalam optimasi adalah sebagai berikut.

1. Penyandian Gen (Pengkodean)

Gen menyimpan nilai-nilai dari variabel yang akan dioptimasi. Pada penelitian ini setiap gen mempresentasikan sebuah bobot pada FERNN.

2. Membangkitkan Populasi Awal

Populasi adalah kumpulan dari individu dimana individu adalah kumpulan dari beberapa gen. Pada penelitian ini bobot akhir dari model FERNN digunakan sebagai individu pertama pada populasi awal sedangkan individu kedua hingga ke 20 dibangkitkan dari nilai acak.

3. Evaluasi Nilai *Fitness*

Nilai *fitness* digunakan untuk mengetahui baik tidaknya suatu individu. Individu terbaik ditunjukkan dengan nilai *fitness* yang paling besar

dalam populasi. Tujuan dari optimasi ini adalah mencari bobot yang menghasilkan *error* terkecil, sehingga nilai *fitness* pada penelitian ini dapat dihitung menggunakan persamaan:

$$f = \frac{1}{x + \alpha} \quad (6)$$

dengan x adalah nilai MAPE dan α adalah nilai yang cukup kecil, pada penelitian ini digunakan 0,0001.

4. Etilism

Individu dengan nilai *fitness* terbaik akan dipertahankan karena proses seleksi dilakukan secara acak sehingga tidak ada jaminan bahwa individu dengan nilai *fitness* terbaik terpilih, mungkin nilai *fitness* tersebut dapat rusak karena proses pindah silang dan mutasi.

5. Seleksi

Seleksi merupakan proses untuk memilih individu yang akan digunakan pada proses pindah silang dan mutasi. Teknik seleksi yang digunakan pada penelitian ini adalah *Rank-Based Fitness Assignment* (Seleksi *Ranking*). Probabilitas terpilih individu pada seleksi ini berdasarkan *ranking* dari nilai *fitness*nya, bukan berdasarkan nilai objektif *fitness*nya.

6. Pindah Silang (*Crossover*)

Pindah silang digunakan untuk membentuk individu baru dari dua induk yang terseleksi. Pada penelitian ini teknik pindah silang yang digunakan adalah pindah silang aritmatika dengan persamaan:

$$u'_1(k) = r \cdot u_1(k) + (1 - r) \cdot u_2(k) \quad (7)$$

$$u'_2(k) = r \cdot u_2(k) + (1 - r) \cdot u_1(k) \quad (8)$$

dengan u'_1 adalah nilai gen pada anak 1, u'_2 adalah nilai gen pada anak 2, r adalah nilai acak [0 1], k adalah posisi gen yang dilakukan pindah silang, u_1 adalah nilai gen pada induk 1 yang akan dipindah silangkan dan u_2 adalah nilai gen pada induk 2 yang akan dipindah silangkan.

7. Mutasi

Mutasi merupakan proses mengubah nilai dari gen dalam suatu anak yang telah dihasilkan pada pindah silang. Mutasi bertujuan untuk memperoleh individu-individu baru sebagai kandidat solusi pada generasi mendatang dengan *fitness* yang lebih baik. Teknik mutasi yang digunakan pada penelitian ini adalah *random mutation* dimana nilai gen terpilih diganti dengan nilai random.

8. Pembentukan Populasi Baru

Pembentukan populasi baru ini didasarkan pada keturunan-keturunan baru hasil mutasi ditambah dengan individu terbaik setelah dipertahankan

dengan proses etilism. Setelah populasi baru terbentuk, dilakukan pengulangan langkah 3-8. Proses ini berlangsung hingga diperoleh solusi atau mencapai generasi yang telah ditentukan.

Hasil dan Pembahasan

Model Fuzzy Elman Recurrent Neural Network (FERNN) yang dioptimasi dengan algoritma genetika akan digunakan untuk meramalkan saham PT Tambang Batubara Bukit Asam Tbk (PTBA) dengan prosedur yang telah diterangkan sebelumnya. Semua data diperoleh dari <https://finance.yahoo.com/> dengan periode data bulan November 2010 hingga April 2017.

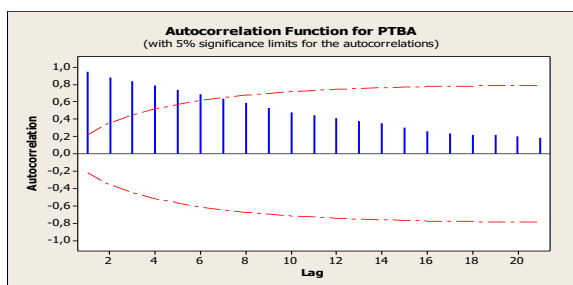
A. Pembentukan model FERNN

Proses membangun model arsitektur FERNN untuk meramalkan harga saham perusahaan diatas terdiri dari menentukan input jaringan, membagi data, fuzzifikasi, menentukan model jaringan terbaik. Laporan lengkap proses pembangunan model FERNN yang diberikan dalam artikel ini hanya untuk satu saham saja yaitu PTBA.

Proses pembangunan model FERNN saham PTBA adalah sebagai berikut.

a. Menentukan Input Jaringan

Menentukan variabel input dengan menggunakan plot ACF. Plot ACF dari variabel input disajikan pada gambar 2.



Gambar 2. Plot ACF PTBA

Pada plot tersebut menunjukkan bahwa lag-lag yang signifikan, yaitu lag 1 hingga lag 6. Dari plot ACF maka diperoleh 6 variabel input sebagai berikut: X_1 = data PTBA ke t-1, X_2 = data PTBA ke t-2, X_3 = data PTBA ke t-3, X_4 = data PTBA ke t-4, X_5 = data PTBA ke t-5, X_6 = data PTBA ke t-6 dan Y_t = data PTBA ke t. Dimana t adalah waktu pengamatan.

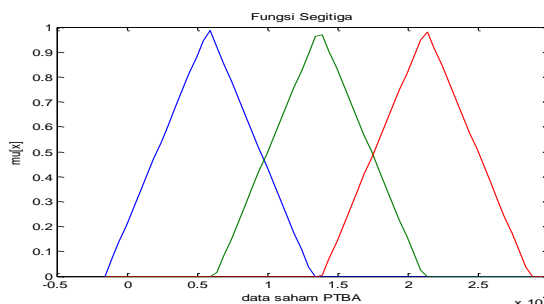
b. Pembagian Data

Data untuk peramalan pada model Fuzzy Elman Recurent Neural Network dibagi menjadi 2 bagian yaitu data training dan data testing. Pada tugas akhir ini, akan digunakan pembagian data

dengan perbandingan 75% data training dan 25% data testing. Dari 71 data yang terpakai didapatkan 53 data untuk data training dan 18 data untuk data testing.

c. Fuzzifikasi

Pada tahap ini data saham PTBA dihitung derajat keanggotaannya dengan menggunakan fungsi keanggotaan Segitiga. Dengan bantuan MATLAB R2013a diperoleh grafik keanggotaan himpunan fuzzy seperti pada Gambar 3.



Gambar 3. Grafik keanggotaan himpunan fuzzy A_1 hingga A_3

Dari gambar 3 diperoleh tiga fungsi keanggotaan yaitu:

$$\mu_{A1}(x) = \begin{cases} 0 & x \leq -1580 \text{ atau } x \geq 13200 \\ \frac{x+1580}{5820+1580} & -1580 < x \leq 5820 \\ \frac{13200-x}{13200-5820} & 5820 < x \leq 13200 \end{cases} \quad (9)$$

$$\mu_{A2}(x) = \begin{cases} 0 & x \leq 6300 \text{ atau } x \geq 21100 \\ \frac{x-6300}{13700-6300} & 6300 < x \leq 13700 \\ \frac{21100-x}{21100-13700} & 13700 < x \leq 21100 \end{cases} \quad (10)$$

$$\mu_{A3}(x) = \begin{cases} 0 & x \leq 13890 \text{ atau } x \geq 28690 \\ \frac{x-13890}{21290-13890} & 13890 < x \leq 21290 \\ \frac{28690-x}{28690-21290} & 21290 < x \leq 28690 \end{cases} \quad (11)$$

d. Menentukan model jaringan terbaik

Pembentukan model dilakukan dengan menentukan parameter pembelajaran dan menentukan banyaknya neuron pada lapisan tersembunyi.

1) Penetapan parameter pembelajaran

Parameter yang digunakan pada skripsi ini ditentukan dengan trial dan error. Parameter pembelajaran terlihat pada tabel 1.

Tabel 1. Parameter Pembelajaran

Parameter	Nilai	Parameter	Nilai
MaxEpoch	5000	IncLearningRate	1,2
TargetError	1e-5	DecLearningRate	0,6
MaxPerfInc	1,06	Momentum	0,8

2) Menentukan banyaknya neuron

Penentuan ini dilakukan dengan melihat nilai MAPE terkecil dengan teknik *defuzzifikasi* yaitu Smallest of maximum (Min), Largest of maximum (Max) dan Mean of maximum (Mean). Hasil percobaan terlihat pada tabel 2.

Tabel 2. Hasil MAPE Model FERNN

Neuron	Nilai MAPE					
	Training			Testing		
	Min	Max	Mean	Min	Max	Mean
1	80,61	12,72	46,7	106,3	33,67	70,0
2	80,49	12,46	46,5	108,7	31,20	70,0
3	79,90	11,04	45,5	153,2	26,10	89,7
4	79,67	11,56	45,6	109,8	30,14	70,0
5	79,62	9,76	44,7	95,7	44,20	69,9
6	79,42	10,42	44,9	110,8	33,07	71,9
7	79,63	9,72	44,7	88,8	51,23	70,0
8	80,05	10,07	45,1	86,6	53,30	70,0
9*	79,65	9,69	44,7	123,1	25,02	74,1
10	79,35	10,32	44,8	79,4	60,52	70,0

Keterangan: *) Model terbaik

Dari percobaan tersebut diperoleh 9 neuron pada lapisan tersembunyi yang menghasilkan nilai MAPE terkecil. Sebagai perbandingan, penulis juga melakukan pengujian dengan model ERNN, artinya input model menggunakan data indeks harga saham gabungan tanpa melalui *fuzzifikasi*. Nilai MAPE untuk model ERNN dapat dilihat pada tabel 3.

Tabel 3. Tabel MAPE Model ERNN

Neuron	Training	Testing
1	24,9555	27,3519
2	25,3782	27,4501
3	25,2958	27,3552
4	25,1637	27,3498
5	25,0802	27,3526
6	24,6758	27,3514
7	24,8106	27,3592
8*	24,5000	27,3504
9	24,6082	27,3506
10	24,8246	27,3601

Keterangan: *) Model terbaik

Dari Tabel 3 diperoleh nilai MAPE minimum yaitu 24,5 untuk data *training* dan 27,3504 untuk data *testing*. Nilai MAPE hasil perhitungan model FERNN dan ERNN terlihat pada Tabel 4.

Tabel 4. Perbandingan hasil MAPE model FERNN dengan ERNN

Model	Nilai MAPE	
	Training	Testing
FERNN	9,69	25,02
ERNN	24,50	27,35

Dari dua model yang diuji, terlihat bahwa model FERNN menghasilkan nilai MAPE yang lebih kecil untuk data *training* dan *testing*. Dengan demikian model yang digunakan untuk penentuan input yang optimal adalah model FERNN.

3) Menentukan *input* yang optimal

Penentuan input ini berdasarkan hasil percobaan mengeliminasi beberapa input. Hasil eliminasi dapat dilihat pada Tabel 5.

Tabel 5. Hasil MAPE Eliminasi Model FERNN

Eliminasi	Training	Testing
X_3	12,3875	26,4962
X_1, X_2	17,5329	27,6326
X_1, X_2, X_3	15,4357	25,9164
X_1, X_2, X_3, X_4	10,7128	25,4567
X_1, X_2, X_3, X_4, X_6	10,4428	25,2849
-*	9,69	25,02

Keterangan: *) Model terbaik

Pada tabel 5 terlihat bahwa menggunakan 6 variabel *input* memberikan model yang terbaik karena menghasilkan nilai MAPE terkecil pada data *training* dan *testing*.

4) Menentukan bobot model

Pada algoritma *backpropagation* dengan fungsi pelatihan *trainidx* dilakukan dengan menginisialisasi bobot awal dengan bilangan acak yang cukup kecil. Dengan berjalannya pelatihan bobot-bobot awal tersebut mengalami perubahan hingga menghasilkan model yang terbaik seperti pada langkah 1 dan 2 di atas. Bobot-bobot yang menghasilkan model terbaik tersebut yang akan digunakan dalam proses peramalan.

5) Model jaringan FERNN

Model jaringan terbaik yang terbentuk terdiri dari 6 variabel *input*, 9 neuron pada lapisan tersembunyi dan neuron tambahan dan 1 neuron pada lapisan *output*.

B. Optimasi Model FERNN dengan Algoritma Genetika

Langkah pertama dalam optimasi ini adalah membentuk populasi awal. Pada pembentukan populasi awal bobot akhir FERNN digunakan sebagai individu pertama. Untuk individu kedua hingga ke 20 dibangkitkan dengan nilai acak. Kemudian populasi awal tersebut digunakan untuk mencari bobot yang lebih baik dengan tahapan-tahapan pada AG. Dengan beberapa percobaan AG diperoleh hasil sebagai berikut:

Tabel 6. Hasil Percobaan Algoritma Genetika

Percobaan ke	Ukuran populasi	Jumlah generasi	Nilai <i>fitness</i>
1	10	50	0,06747
2	10	100	0,06853
3	10	150	0,07148
4	20	50	0,07167
5	20	100	0,07148
6	20	150	0,07201
7	30	50	0,07032
8	30	100	0,07156
9	30	150	0,07155
10	40	50	0,07166

Bobot hasil optimasi dengan AG pada percobaan ke 11 kemudian digunakan untuk menghitung nilai MAPE pada data *training* dan data *testing*. MAPE hasil perhitungan terlihat pada Tabel 7 berikut.

Tabel 7. Perbandingan hasil MAPE

Model	Nilai MAPE	
	<i>Training</i>	<i>Testing</i>
FERNN tanpa optimasi	8,3237	43,0113
Algoritma Genetika		
FERNN dengan optimasi	6,9498	6,9642
Algoritma Genetika		

Pada tabel 7 terlihat jelas bahwa kinerja FERNN dengan optimasi AG untuk data *training* maupun *testing* lebih baik dibandingkan dengan tanpa algoritma genetika. Model FERNN terbaik yang diperoleh secara matematis dapat ditulis sebagai berikut:

$$Y_{ts} = \sum_{k=1}^9 v_k(s) \frac{1 - \exp(-(\sum_{i=1}^9 \sum_{k=1}^9 x_i w_{ik}(s) + \sum_{j=1}^9 \sum_{k=1}^9 u_k w_{jk} + b_k))}{1 + \exp(-(\sum_{i=1}^9 \sum_{k=1}^9 x_i w_{ik}(s) + \sum_{j=1}^9 \sum_{k=1}^9 u_k w_{jk} + b_k))} + b_{0,s}$$

(8)

Dengan bobot-bobot akhir hasil pembelajaran adalah sebagai berikut:

$$b_k = [-2,4257 \quad \dots \quad 0,3333]$$

$$v_k(1) = \begin{bmatrix} 0,5611 \\ \vdots \\ 0,7874 \end{bmatrix} \quad v_k(2) = \begin{bmatrix} -0,5567 \\ \vdots \\ -0,8983 \end{bmatrix} \quad v_k(3)$$

$$= \begin{bmatrix} -0,3941 \\ \vdots \\ 0,2310 \end{bmatrix}$$

$$b_{0,1} = [0,6185] \quad b_{0,2} = [0,2093]$$

$$b_{0,3} = [-0,2698]$$


$$w_{ik}(1) = \begin{bmatrix} 0,6213 & \dots & 0,5747 \\ \vdots & \dots & \vdots \\ -0,0041 & \dots & 0,1578 \end{bmatrix}$$

$$w_{ik}(2) = \begin{bmatrix} -0,1868 & \dots & -0,5325 \\ \vdots & \dots & \vdots \\ -0,0279 & \dots & 0,3194 \end{bmatrix}$$

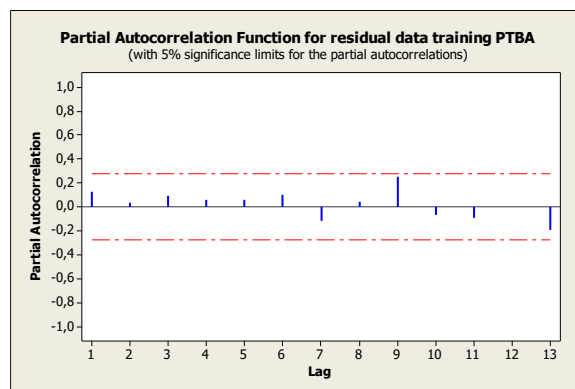
$$w_{ik}(3) = \begin{bmatrix} -2,2027 & \dots & 2,9072 \\ \vdots & \dots & \vdots \\ 2,5235 & \dots & -1,0824 \end{bmatrix}$$

$$w_{jk} = \begin{bmatrix} -0,0446 & \dots & 0,1577 \\ \vdots & \ddots & \vdots \\ 0,1129 & \dots & -0,0026 \end{bmatrix}$$

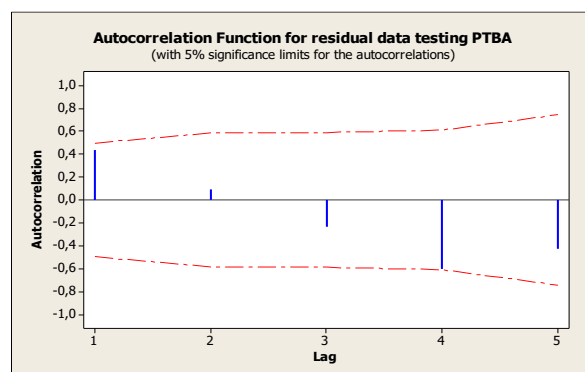
Model terbaik yang diperoleh terlebih dahulu diuji sebelum digunakan untuk peramalan. Pengecekan *error* pada model dilakukan dengan melihat plot ACF dan PACF dari residual data *training* dan *testing* yang ditunjukkan pada Gambar 4 sampai Gambar 7 berikut.



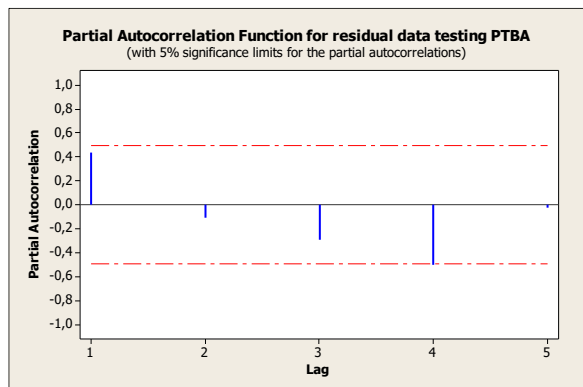
Gambar 4. Plot ACF residual data training



Gambar 5. Plot PACF residual data training



Gambar 6. Plot ACF residual data testing



Gambar 7. Plot PACF residual data testing

Jelas terlihat tidak ada lag yang signifikan atau melebihi garis kepercayaan. Dengan kata lain, error bersifat acak atau white noise terpenuhi. Oleh karena itu, model FERNN dengan arsitektur jaringan 6 variabel input, 9 neuron pada lapisan tersembunyi dan 1 neuron pada lapisan output dapat digunakan untuk meramalkan saham PTBA.

C. Peramalan menggunakan model FERNN dengan optimasi evolutif

Untuk meramalkan harga saham di bulan Mei 2017 atau Y_{72} , digunakan nilai input harga saham bulan November 2016–April 2017 pada Tabel 8.

Tabel 8. Nilai input untuk prediksi Mei 2017

Input	Data Asli	Hasil Fuzzifikasi		
		A_1	A_2	A_3
Y_{66}	21250	0	0,959459	0,014865
Y_{67}	22300	0	0,689189	0,285135
Y_{68}	21000	0	0,662162	0,312162
Y_{69}	20050	0	0,878378	0,095946
Y_{70}	19750	0	0,702703	0,271622
Y_{71}	22950	0	0,871622	0,102703

Berdasarkan model FERNN yang terbentuk maka perhitungan peramalan bulan November 2017 adalah sebagai berikut:

$$\begin{aligned}
 U_{net_1} &= \sum_{i=1}^4 \sum_{k=1}^6 x_i w_{ik}(1) + b_k \\
 &= [0 \ 0 \ 0 \ 0 \ 0 \ 0] \begin{bmatrix} 0,6213 & \dots & 0,5747 \\ \vdots & \dots & \vdots \\ -0,0041 & \dots & 0,1578 \end{bmatrix} + \\
 &\quad [-2,4257 \ \dots \ 0,3333] \\
 &= [-2,4257 \ \dots \ 0,3333] \\
 U_1 &= \frac{1 - e^{-(U_{net_1})}}{1 + e^{-(U_{net_1})}} = \frac{1 - e^{-[-2,4257 \ \dots \ 0,3333]}}{1 + e^{-[-2,4257 \ \dots \ 0,3333]}} \\
 &= [-0,8375 \ \dots \ 0,3235]
 \end{aligned}$$

$$\begin{aligned}
 T_{net_1} &= \sum_{i=1}^4 \sum_{k=1}^6 x_i w_{ik}(s) + \sum_{j=1}^6 \sum_{k=1}^6 u_k w_{jk} + b_k \\
 &= U_{net_1} + \sum_{j=1}^6 \sum_{k=1}^6 u_k w_{jk} \\
 &= [-2,4257 \ \dots \ 0,3333] + \\
 &\quad [-0,8375 \ \dots \ 0,3235] \begin{bmatrix} 0,6213 & \dots & 0,5747 \\ \vdots & \dots & \vdots \\ -0,0041 & \dots & 0,1578 \end{bmatrix} \\
 &= [-2,6811 \ \dots \ -0,5639] \\
 T_1 &= \frac{1 - e^{-(T_{net_1})}}{1 + e^{-(T_{net_1})}} = \frac{1 - e^{-[-2,6811 \ \dots \ -0,5639]}}{1 + e^{-[-2,6811 \ \dots \ -0,5639]}} \\
 &= [-0,8718 \ \dots \ -0,1012]
 \end{aligned}$$

Perhitungan nilai y_{t_s} untuk s=1

$$\begin{aligned}
 Y_{72,1} &= \sum_{k=1}^6 v_k(1)T_k + b_{0,1} \\
 &= \begin{bmatrix} 0,5611 \\ \vdots \\ 0,7874 \end{bmatrix} [-0,8718 \ \dots \ -0,1012] + 0,6185 = \\
 &\quad 0,3987
 \end{aligned}$$

Perhitungan nilai y_{t_s} untuk s=2

$$\begin{aligned}
 Y_{72,2} &= \sum_{k=1}^6 v_k(2)T_k + b_{0,2} \\
 &= \begin{bmatrix} -0,5567 \\ \vdots \\ -0,8983 \end{bmatrix} [0,9326 \ \dots \ -0,6738] + 0,2093 = \\
 &\quad 0,0634
 \end{aligned}$$

Perhitungan nilai y_{t_s} untuk s=3

$$\begin{aligned}
 Y_{72,3} &= \sum_{k=1}^6 v_k(3)T_k + b_{0,3} \\
 &= \begin{bmatrix} -0,3941 \\ \vdots \\ 0,2310 \end{bmatrix} [0,995 \ \dots \ -0,962] - 0,2698 = \\
 &\quad 0,0213
 \end{aligned}$$

Diperoleh nilai $Y_{84,s} = [0,3987 \ 0,0634 \ 0,0213]$.

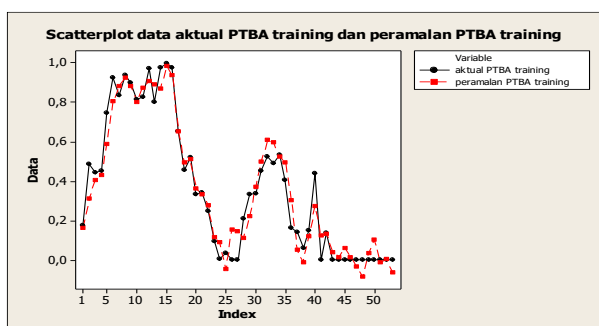
Metode defuzzifikasi yang digunakan pada skripsi ini adalah Largest of Maximum Defuzzifier. Solusi crisp dari metode ini diperoleh dengan mengambil nilai terbesar dari domain yang memiliki derajat keanggotaan maksimum sehingga nilai peramalan yang dipilih adalah 0,3987. Nilai 0,3987 berada di s = 1, sehingga terletak pada himpunan fuzzy kedua yaitu A_1 dan data yang digunakan adalah data pada μ_{A1} .

Untuk nilai peramalan saham PTBA pada bulan Mei 2017 s.d. Oktober 2017 tersaji pada Tabel 9.

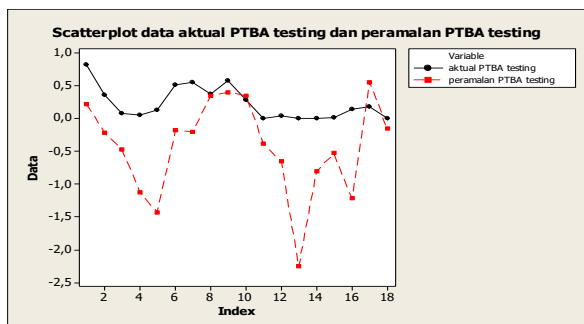
Tabel 9. Hasil data peramalan pada bulan Mei 2017 s.d. Oktober 2017

Bulan	Data Peramalan
Mei 2017	9250
Juni 2017	9709
Juli 2017	10387
Agustus 2017	10045
September 2017	9545
Oktober 2017	9750

Plot data aktual dan hasil peramalan untuk data *training* dan data *testing* terlihat pada Gambar 9 dan 10 di bawah ini.



Gambar 9. Plot data aktual dan peramalan data *training*



Gambar 10. Plot data aktual dan peramalan data *testing*

Simpulan

Arsitektur model FERNN terbaik telah diperoleh untuk setiap harga saham dengan variabel *input* bilangan fuzzy dengan fungsi keanggotaan segitiga, dan fungsi aktivasi *sigmoid bipolar* pada lapisan tersembunyi dan lapisan tambahan serta *linear* pada lapisan *output*. Dari optimasi bobot-bobot akhir Fuzzy Elman Recurrent Neural Network menggunakan Algoritma Genetika didapatkan nilai MAPE yang lebih kecil dari FERNN tanpa optimasi. Penelitian lanjutan dapat dilakukan dengan menggunakan fungsi keanggotaan selain kurva-S pertumbuhan dan kurva segitiga, serta menggunakan RNN dengan

jaringan Hopfield, sedangkan pada algoritma genetika dapat menggunakan teknik seleksi lain seperti *Roulette wheel* dan pada mutasi dapat menggunakan *shift mutation*.

Ucapan Terima Kasih

Ucapan terima kasih ditujukan kepada RISTEK DIKTI melalui FMIPA UNY atas Dana Penelitian Dosen Berbasis Kelompok Bidang Keahlian. Artikel ini merupakan hasil dari penelitian tersebut yang didesiminasi melalui jurnal ilmiah.

Pustaka

- [1] Pallit, A., Popovic, D. (2005) *Computational Intelligence in Time Series Forecasting*. Heidelberg: Springer.
- [2] Yuce, B., Li, H., Rezgui, Y., Petri I., Jayan B., Yang C. (2014), Utilizing artificial neural network to predict energy consumption and thermal comfort levels: an indoor swimming pool case study, *Energy Build.* 80, 45–46.
- [3] Jang, Sun, Mizutani. (1997) *Neuro-Fuzzy and Soft Computing*. Upper Saddle River: Prentice Hall.
- [4] Kusumadewi, S., Hartati, S. (2005) *Neuro-Fuzzy: integrasi sistem fuzzy dan jaringan syaraf*. Yogyakarta: Graha Ilmu.
- [5] Bhandari, R., & Gill, J. (2016), An artificial Intelligence ATM forecasting system for hybrid neural networks. *International Journal of Computer Applications*.133, 13–16.
- [6] Zhang, F., Deb, C., Lee, S. E., Yang, J., & Shah, K. W. (2016), Time series forecasting for building energy consumption using weighted support vector regression with differential evolution optimization technique. *Energy and Buildings*, 126, 94–103.
- [7] Wiliansa, G., Kusumawati, R., (2017), Optimasi fuzzy backpropagation neural network dengan algoritma genetika untuk memprediksi nilai tukar rupiah terhadap dollar amerika. Skripsi S1, UNY Yogyakarta. Tidak Dipublikasikan.
- [8] Rizka, B. G. A., Kusumawati, R., (2017), Fuzzy feed forward neural network untuk peramalan indeks harga saham gabungan (ihsg) dengan algoritma genetika menggunakan variasi seleksi. Skripsi S1, UNY Yogyakarta. Tidak Dipublikasikan.
- [9] Hanke, J.E., Wichern, D.W. (2005) *Bussiness Forecasting*, 8 ed. New Jersey: Prentice-Hall.