

## PREDIKSI NILAI TUKAR MATA UANG ASING MENGGUNAKAN *EXTREME LEARNING MACHINE*

**Septiana Dwi Anggraini**

(S1 Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Surabaya)

e-mail: septianadwia@ mhs.unesa.ac.id

### Abstrak

Valuta asing adalah perdagangan nilai mata uang asing dari suatu negara dengan negara lain. Di Indonesia valuta asing dijadikan salah satu investasi, sehingga berbagai cara prediksi dilakukan agar mengurangi resiko kerugian investasi. Prediksi ini dilakukan secara analisis teknikal pada kurs jual dan kurs beli dengan menggunakan metode extreme learning machine (ELM). Terdapat dua proses pada, pertama proses pelatihan dan kedua adalah proses uji. Pada proses ELM diperoleh model optimal pada jumlah node 25 pada hidden node pada kurs jual dan kurs beli. Proses pelatihan ini telah di uji dengan hasil error sebesar 0.001296 pada kurs jual dan 0.001099 pada kurs beli. Model tersebut digunakan untuk memprediksi pada bulan Februari. Dari hasil prediksi diperoleh nilai error sebesar 0.000368 pada kurs jual dan diperoleh nilai error sebesar 0.001596 pada kurs beli.

**Kata Kunci :** Prediksi, Valuta Asing dan *Extreme Learning Machine*.

### Abstract

Foreign exchange is trading value of foreign exchange of a country to other countries. In Indonesia, foreign exchange is used to be an investment, therefore prediction already doing to reduce the risk of investment loss. In this study, foreign exchange prediction has been done using extreme learning machine (ELM) method. There are two phase of ELM, the first is training phase, and testing phase. Using ELM we got the optimal model is obtained at 25 hidden nodes at the selling rate and buying rate. This training process has been tested with an error of 0.001296 on the selling rate and 0.001099 at the buying rate. The model was used to predict in February. Prediction results is error value of 0.000368 at the selling rate and obtained an error of 0.001596 on the buying rate.

**Keyword :** Forecasting, Foreign Exchange, and Extreme Learning Machine.

### PENDAHULUAN

Valuta Asing (Valas) adalah suatu mekanisme yang memperlihatkan diperdagangkannya mata uang asing suatu negara terhadap mata uang lain (Ming,2011). Valas pada dasarnya merupakan perdagangan nilai mata uang asing dari berbagai dunia. Transaksi valas ini dilakukan dengan cara memindahbukukan dana pada rekening bank antara *trader*. Para *trader* ini diantaranya yaitu pemerintah-pemerintah dunia, bank-bank utama dunia, perusahaan bertaraf internasional, *hedge fund*, spekulan valas maupun individu. Banyaknya pemain ini menyebabkan perputaran uang menjadi sangat cepat.

Nilai tukar valas selalu berubah-ubah setiap waktu, oleh karena itu sangatlah penting untuk mengetahui risiko-risiko yang terdapat dalam perdagangan valuta asing sehingga dapat dikembangkan suatu kebijakan untuk mengatasi risiko. Setiap pemain

akan melakukan beberapa analisis, analisis tersebut yaitu analisis fundamental dan analisis teknikal (Luca,1995).

Analisis tersebut digunakan untuk memprediksi valuta asing. Prediksi sendiri merupakan metode untuk memperkirakan suatu nilai di masa depan dengan menggunakan data masa lalu (Gaspersz,2002). Menurut Assauri (1984) ada berbagai macam jenis prediksi, namun pada penelitian ini jenis prediksi yang dilakukan merupakan prediksi jangka pendek yang bersifat objektif dan kuantitatif karena data yang digunakan merupakan data selama satu tahun. Data tersebut berbentuk harian sehingga prediksi ini merupakan prediksi *time series*.

Salah satu metode yang digunakan untuk memprediksi yaitu Jaringan Syaraf Tiruan (JST). Jaringan syaraf tiruan merupakan pemodelan data yang kuat yang mampu menangkap dan mewakili hubungan *input-output* yang kompleks . Dalam beberapa dekade terakhir, JST sering digunakan untuk memecahkan

masalah rumit dan untuk meguji hubungan antara variabel yang berbeda.

JST menunjukkan bahwa metode ini dapat digunakan sebagai alat efisien untuk menganalisa isu-isu penting dalam keputusan bisnis (Aydin, et al, 2015). Lebih lanjut lagi Aydin, *et al* dalam penelitiannya mengenai prediksi Harga Emas, Indeks Bursa Istanbul (BIST) 100, dan nilai tukar US Dollar-Turkish Lira (USD/TRY), dikemukakan juga bahwa metode JST menghasilkan estimasi yang lebih baik dan hasil yang lebih akurat.

Penelitian prediksi pertukaran valuta asing ini menggunakan metode *extreme learning machine (ELM)*. Metode *Extreme learning machine* merupakan perkembangan dari jaringan syaraf tiruan. *Extreme learning machine* pertama kali diperkenalkan oleh Huang (2006). ELM merupakan jaringan *feedforward* dengan *single hidden layer*. Metode pembelajaran ELM dibuat untuk mengatasi kelemahan-kelemahan dari jaringan syaraf tiruan *feedforward* terutama dalam hal *learning speed*. Pada ELM, parameter-parameter dipilih secara random, sehingga ELM memiliki *learning speed* yang cepat.

**EXTREME LEARNING MACHINE**

Arsitektur jaringan *Extreme Learning Machine (ELM)* terdiri dari 3 lapisan, yaitu lapisan input, lapisan tersembunyi dan lapisan output. ELM menggunakan satu lapisan tersembunyi atau yang biasa disebut dengan *Single Hidden Layer Feedforward Neural Networks (SLFNs)*. Huang *et al* mengemukakan dua alasan mengapa jaringan syaraf tiruan *feedforward* mempunyai *learning speed* rendah, yaitu semua parameter pada jaringan ditentukan secara iterative dengan menggunakan metode pembelajaran tersebut. Parameter dari jaringan syaraf *feedforward* harus ditentukan secara manual, yaitu parameter bobot input dan parameter hidden bias. Parameter – parameter tersebut saling berhubungan antara *layer* yang satu dengan *layer* yang lainnya, sehingga membutuhkan *learning speed* yang lama. Sedangkan pada ELM, parameter-parameter tersebut dipilih secara random, sehingga ELM memiliki *learning speed* yang cepat. (Umi *et al*, 2015)

Model matematis dari ELM lebih sederhana dan efektif dari jaringan syaraf tiruan lainnya.

$$\sum_{i=1}^N \beta_i g(x_j) = \sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) = o_j, j \in [1, N] \quad (1)$$

Dimana  $b_i$  adalah nilai bias pada node *hidden* dan  $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$  adalah bobot penghubung  $i$  node hidden dengan node input.  $\beta_i = [\beta_1, \beta_2, \dots, \beta_i]^T$  adalah bobot output atau bobot akhir, yaitu bobot penghubung  $i$  node hidden dan node output.

Fungsi aktivasi yang digunakan adalah fungsi aktivasi *sigmoid biner* dan *error* rata-rata nol,  $\sum_{i=1}^N \|o_j - t_i\| = 0$  terdapat  $\beta_i, w_i$ , dan  $b_i$  sehingga:

$$\sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) = t_j, j \in [1, N] \quad (2)$$

Dapat ditulis  $H\beta_i = T$

$H$  adalah *output* matriks *hidden layer*, kolom ke  $i$  adalah *output hidden node* ke  $i$ , dengan

$$H = \begin{bmatrix} g(w_1 x_1 + b_1) & \dots & g(w_{\tilde{N}} x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ g(w_1 x_N + b_1) & \dots & g(w_{\tilde{N}} x_N + b_{\tilde{N}}) \end{bmatrix} \quad (3)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_{\tilde{N}} \end{bmatrix} \text{ dan } T = \begin{bmatrix} t_1 \\ \vdots \\ t_{\tilde{N}} \end{bmatrix} \quad (4)$$

Algoritma ELM digunakan pada proses pelatihan untuk mendapatkan model yang digunakan untuk prediksi. Menurut (Sun, Choi, Au, Yu, 2008), ELM menghasilkan output prediksi yang stabil dengan jumlah hidden node 0-30. Konsep utama dari ELM seperti yang disajikan dalam paper Huang (2006) adalah sebagai berikut:

Diberikan *training set*  $\aleph = \{(x_j, t_j) | x_j \in R^n, t_j \in R^m, j \in [1, N]\}$ , fungsi aktivasi  $g(x)$ , dan bilangan *hidden node*  $\tilde{N}$

Langkah 1: masukkan secara random bobot input  $w_i$  dan bobot hidden  $b_i, i \in [1, \tilde{N}]$

Langkah 2: hitung *output* matriks *hidden layer*  $H_{n \times m}$

Langkah 3: hitung bobot *output*  $\beta$

$$\beta = H^\dagger T \quad (5)$$

Dimana  $T = [t_1, t_2, \dots, t_N]^T$

$H^\dagger$  adalah *Generalized Inverse*

$$H^\dagger = (H^T H)^{-1} H^T$$

$$H^\dagger = H^T (H H^T)^{-1} \quad (6)$$

**METODE PENELITIAN**

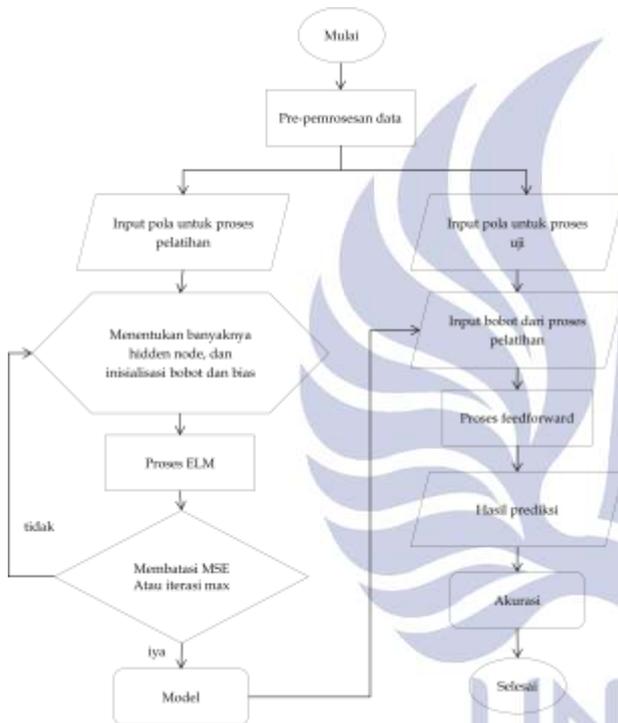
**A. Teknik Pengumpulan Data**

Data yang digunakan dalam penelitian ini merupakan data sekunder yang berupa kurs Bank Indonesia, yaitu data kurs jual dan kurs beli yang

menunjukkan fluktuatif kurs antara mata uang Dollar Amerika (USD) dengan mata uang Rupiah (IDR). Data sekunder diperoleh dari website www.bi.go.id. Data yang digunakan adalah data harian yang teraktual terhadap data kurs yang diperoleh, yaitu terhitung dari tanggal 4 Januari 2016 sampai 31 Januari 2017.

**B. Alur Penelitian**

Alur penelitian untuk menerapkan algoritma ELM ada beberapa tahapan, yaitu pra-pemrosesan data, proses pelatihan, dan proses uji. Secara umum, alur penelitian digambarkan sebagai berikut:



Gambar 1. Alur Skema Extreme Learning Machine

**C. Perhitungan Akurasi**

Model – model prediksi yang dilakukan kemudian di validasi menggunakan sejumlah indikator. Pada penelitian ini, indikator perhitungan menggunakan Mean Square Error (MSE). MSE sangat baik dalam memberikan gambaran terhadap konsisten model yang dibangun. Dengan meminimalkan nilai MSE, berarti meminimalkan varian model. Model yang memiliki varian kecil mampu memberikan hasil yang relatif lebih konsisten untuk seluruh data input dibandingkan dengan model dengan varian besar. Nilai MSE dapat dihitung dengan menggunakan rumus sebagai berikut:

$$MSE = \frac{\sum e_j^2}{N} = \frac{\sum (X_j - Y_j)^2}{N} \tag{7}$$

Dimana:

$X_j$  = nilai aktual ke j

$Y_j$  = nilai hasil output

$n$  = banyaknya data

**D. Denormalisasi Data**

Denormalisasi dilakukan untuk mengembalikan nilai atau data ke bentuk semula, sehingga hasil nilai atau data dari proses extreme learning machine dapat dengan mudah dibaca dan dipahami. Menurut (Siang, 2005) berikut merupakan persamaan yang digunakan untuk denormalisasi data di dalam interval [0,1] :

$$x = \frac{(x_p - 0.1)(\max(x_p) - \min(x_p))}{0.8} + \min(x_p) \tag{8}$$

Dimana :

$x$  : nilai denormalisasi

$x_p$  : nilai data normalisasi

$\min(x_p)$  : nilai minimum pada data asli

$\max(x_p)$  : nilai maksimum pada data asli

**HASIL DAN PEMBAHASAN**

**A. Pre-pemrosesan ELM**

Data yang diperoleh akan di normalisasi sesuai dengan range fungsi aktifasi sigmoid biner yaitu [0,1]. Menurut Siang (2005) persamaan yang digunakan untuk normalisasi yaitu:

$$x = \frac{0.8 * (x_p - \min(x_p))}{(\max(x_p) - \min(x_p))} + 0.1 \tag{9}$$

Dimana:

$x$  : input setelah dinormalisasi

$x_p$  : nilai data asli yang belum dinormalisasi

$\min(x_p)$  : nilai minimum pada data set

$\max(x_p)$  : nilai maksimum pada data set

Berikut merupakan hasil normalisasi data:

Tabel 1. Data Normalisasi Kurs Jual dan Kurs Beli

Hari ke-	Tanggal	Kurs jual	Kurs beli
1	4 Januari 2016	0.861756	0.862956
2	5 Januari 2016	0.888293	0.888177
3	6 Januari 2016	0.834439	0.835369
4	7 Januari 2016	0.900000	0.900000
5	8 Januari 2016	0.843024	0.844039
6	11 Januari 2016	0.891415	0.891330
7	12 Januari 2016	0.812585	0.813300
⋮	⋮	⋮	⋮
237	31 Januari 2017	0.427024	0.427094

Data yang diperoleh dari data sekunder selama 4 Januari 2016 hingga 31 Januari 2017 berjumlah 237 data. Selanjutnya data ini dibentuk ke dalam arsitektur

pola sebagai berikut:  $x_j = [x_{j1}, x_{j2}, \dots, x_{jn}]^T \in \mathbb{R}^n, n = 5$  =banyaknya node input  $t_j = [t_{j1}, t_{j2}, \dots, t_{jm}]^T \in \mathbb{R}^m, m = 1$  =banyaknya node output,  $j = N$ , banyaknya data.

Tabel 2. Arsitektur Pola

Data	Node Input					Target
$j$	$x_{j1}$	$x_{j2}$	$x_{j3}$	$x_{j4}$	$x_{j5}$	$t_j$
1	Hari ke-1	Hari ke-2	Hari ke-3	Hari ke-4	Hari ke-5	Hari ke-6
2	Hari ke-2	Hari ke-3	Hari ke-4	Hari ke-5	Hari ke-6	Hari ke-7
⋮	⋮	⋮	⋮	⋮	⋮	⋮
232	Hari ke-232	Hari ke-233	Hari ke-234	Hari ke-235	Hari ke-236	Hari ke-237

Banyaknya node input yaitu sebanyak 5 node dengan asumsi bahwa 5 node input ini mewakili 5 hari kerja dalam sepekan. Pada tabel 2 merupakan arsitektur data yang akan digunakan dalam proses pelatihan dan proses uji dengan metode *extreme learning machine*. Karena hari ke-1 hingga hari ke-5 merupakan data pertama, sedangkan data yang diperoleh sebanyak 237 hari, maka banyaknya data yang terbentuk yaitu sebanyak 232 data. Selanjutnya pola tersebut akan dibagi menjadi 2 bagian yaitu data untuk proses pelatihan dan data untuk proses uji. Pada penelitian ini digunakan beberapa macam rasio untuk pembagian data, yaitu 60:40, 70:30 dan 80:20. Nilai target pada proses pelatihan ini digunakan pada perhitungan bobot akhir pada proses pelatihan *extreme learning machine*. Berbeda dengan data pelatihan, nilai target pada data uji digunakan untuk mengetahui tingkat akurasi dari hasil pelatihan.

**B. Analisis Hasil Proses Extreme Learning Machine**

Pada proses pelatihan ELM penentuan jumlah node pada *hidden layer* ditentukan pada awal pembentukan jaringan. Jumlah node yang digunakan mulai dari node 1 hingga jumlah node 30. Setelah mendapatkan beberapa model pada proses pelatihan, kemudian model tersebut di uji nilai akurasi terkecil pada proses uji. Nilai akurasi yang terkecil ini menunjukkan bahwa model telah optimal dan dapat digunakan untuk input prediksi. Pada tiap kurs jual dan kurs beli diperoleh masing – masing model optimal. Bentuk umum model yang diperoleh yaitu:

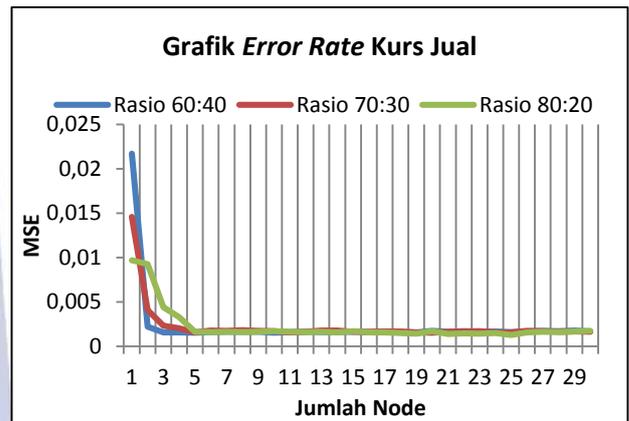
$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = y_j, j \in [1, N]$$

Dimana  $N$  merupakan jumlah data,  $\tilde{N}$  adalah banyaknya node pada *hidden layer* dan  $g(z)$  adalah fungsi aktifasi sigmoid. Nilai pada setiap bobot dan bias pada model

optimal diperoleh dari proses pelatihan. Berikut merupakan nilai akurasi pada setiap model node:

Tabel 3. Hasil Proses ELM Kurs Jual

Node	Error Rate		
	Rasio 60:40	Rasio 70:30	Rasio 80:20
$\tilde{N}$			
5	0.001548	0.001585	0.001632
10	0.001519	0.001705	0.001733
15	0.001636	0.001628	0.001732
20	0.001743	0.001531	0.001733
25	0.001598	0.001586	0.001296
30	0.001672	0.001635	0.001759

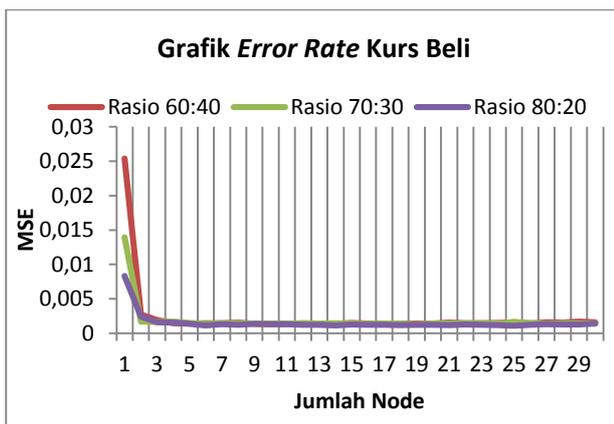


Gambar 2. Grafik nilai MSE pada setiap node Kurs Jual proses ELM

Dari gambar grafik diatas dapat disimpulkan bahwa nilai akurasi menggunakan *mean square error* memiliki nilai yang stabil pada jumlah hidden node ke 5 hingga 30 pada semua rasio pembagian data. Untuk mendapatkan model yang optimal, penulis mensortir nilai akurasi yang terkecil dari semua nilai akurasi pada rasio. Nilai akurasi terkecil diperoleh sebesar 0.001296 terdapat pada hidden node ke 25 pada rasio 80:20. Ini berarti penggunaan data pelatihan yang besar akan menghasilkan nilai error yang kecil.

Tabel 4. Hasil Proses ELM Kurs Beli

Node	Error Rate		
	Rasio 60:40	Rasio 70:30	Rasio 80:20
$\tilde{N}$			
5	0.001385	0.001506	0.001351
10	0.001334	0.001419	0.001309
15	0.001521	0.001384	0.001273
20	0.001419	0.001403	0.001215
25	0.001573	0.001661	0.001099
30	0.001607	0.001454	0.001406



Gambar 3. Grafik nilai MSE pada setiap node Kurs Beli proses ELM

Dari gambar grafik diatas dapat disimpulkan bahwa nilai akurasi menggunakan *mean square error* memiliki nilai yang stabil pada jumlah hidden node ke 5 hingga 30 pada semua rasio pembagian data. Untuk mendapatkan model yang optimal, penulis mensortir nilai akurasi yang terkecil dari semua nilai akurasi pada rasio. Nilai akurasi terkecil diperoleh sebesar 0.001099 terdapat pada hidden node ke 25 pada rasio 80:20. Ini berarti penggunaan data pelatihan yang besar akan menghasilkan nilai error yang kecil.

### C. Prediksi

Karena data yang digunakan pada proses ELM yaitu data harian, maka pada penulis memprediksi harga kurs setiap hari kerja selama bulan Februari. Berikut merupakan hasil prediksi pada setiap kurs jual dan kurs beli:

Tabel 5. Hasil Prediksi

Tanggal	Kurs Jual		Kurs Beli	
	Hasil Prediksi	Harga Aktual	Hasil Prediksi	Harga Aktual
01-Feb-17	13405.54	13416	13268.67	13282
02-Feb-17	13402.72	13441	13280.39	13307
03-Feb-17	13399.62	13429	13281.79	13295
06-Feb-17	13398.76	13396	13286.34	13262
07-Feb-17	13396.66	13389	13292.35	13255
08-Feb-17	13395.03	13404	13299.24	13270
09-Feb-17	13393.61	13375	13303.99	13241
10-Feb-17	13392.17	13385	13309.18	13251
13-Feb-17	13390.82	13397	13314.16	13263
14-Feb-17	13389.52	13397	13318.17	13263
16-Feb-17	13388.28	13396	13321.07	13262
17-Feb-17	13387.09	13395	13323.18	13261
20-Feb-17	13385.95	13419	13324.24	13285
21-Feb-17	13384.87	13437	13324.11	13303
22-Feb-17	13383.83	13423	13322.93	13289
23-Feb-17	13382.83	13427	13320.81	13293
24-Feb-17	13381.88	13403	13317.84	13269
27-Feb-17	13380.97	13406	13314.2	13272

Tanggal	Kurs Jual		Kurs Beli	
	Hasil Prediksi	Harga Aktual	Hasil Prediksi	Harga Aktual
28-Feb-17	13380.09	13414	13310.13	13280

Pada tabel 5 terlihat perbandingan harga pada hasil prediksi dengan harga valuta asing sebenarnya. Pada hasil prediksi kurs jual pada bulan Februari diperoleh nilai error sebesar 0.000368, sedangkan hasil prediksi kurs beli pada bulan Februari diperoleh nilai error sebesar 0.001596.

## PENUTUP

### A. Simpulan

Berdasarkan hasil penelitian yang telah dilakukan, pada proses pelatihan dengan metode *extreme learning machine* diperoleh model arsitektur pola untuk prediksi valuta asing untuk kurs jual dan kurs beli. Masing-masing kurs jual dan kurs beli memiliki model arsitektur pola yaitu 5 node input, 25 hidden node dimana input bobot awal, bobot bias dan bobot akhir diperoleh dari model optimal, dan menghasilkan 1 node output yaitu hasil prediksi. Fungsi aktivasi yang digunakan yaitu fungsi aktivasi sigmoid. Model ini telah diuji sehingga menghasilkan nilai error sebesar 0.001296 pada kurs jual dan 0.001099 pada kurs beli.

Setelah memperoleh model optimal, kemudian dilakukan prediksi valuta asing setiap hari kerja selama bulan Februari 2017. Dari hasil prediksi tersebut diperoleh nilai error sebesar 0.000368 pada kurs jual dan diperoleh nilai error sebesar 0.001596 pada kurs beli.

### B. Saran

Data input yang digunakan penulis merupakan data analisis teknikal, pada penelitian selanjutnya dapat menggabungkan data teknikal dengan data fundamental agar diperoleh nilai error yang kecil.

### DAFTAR PUSTAKA

- Alev Dilek Aydin, Seyma Caliskan Cavdar. 2015. "Comparison of Prediction Performances of Artificial Neural Network (ANN) and Vector Autoregressive (VAR) Models by Using the Macroeconomic Variables of Gold Prices, Borsa Istanbul (BIST) 100 Index and US Dollar-Turkish Lira (USD/TRY) Exchange Rates". *Journal of Elsevier*. Vol. 30(2015):pp 3-14.
- Duda, Richard O. Hart, Petter. E. & Stork, David. G. 2001. "Pattern Classification (2nd edition)", Wiley, New York.

- Fausset Laurence. 1994. "Fundamental of Neural Network: Architecture, Algorithm, and Application". New Jersey : Prentice Hall.
- Fikriya, Z. A., & Irawan, M. I. (2017). Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital, 6(1)
- Gaspersz. 2002. Ekonomi Manajerial, Pembuatan Keputusan Bisnis (edisi revisi dan perluasan). Jakarta: Gramedia Pustaka Utama.
- Huang, G.B., Zhu, Q. Y., Siew, C. K, 2006. "Extreme learning machine: Theory and application", *Neurocomputing*. hal.489-501.
- Lei Yu, Zhao Danning, Cai Hongbing. "Prediction of Length-of-Day Using Extreme Learning Machine". *Journal of Elsevier*. Vol. 6 No.2. pp 151-159.
- Luca, Cornelius. 1995. "Trading in the Global Currency Markets". New Jersey: Prentice Hall
- Macausland, R. (2014). University of Puget Sound MATH420: Advanced Topics in Linear Algebra The Moore-Penrose Inverse and Least Squares.
- Ming, T. S. 2001. *Day Trading Valuta Asing*. Graha Ilmu, Yogyakarta.
- National Futures Association (2010). *Trading in the Retail Off-Exchange Foreign Currency Market*. Chicago, Illinois.
- Nur Ulfa Hidayatullah, Ir. Ya'umar, MT, 2014. "Estimasi Radiaasi Matahari Perjam pada Permukaan Horizontal dengan *Extreme Learning Machine* (Studi Kasus di Surabaya)". *Jurnal Teknik POMITS* Vol.2, No.2.
- Singgih Santoso. 2009. "Panduan Lengkap Menguasai Statistik dengan SPSS". Jakarta: PT. Elex Media Komputindo
- Siang, J.J. 2005. "Jaringan Syaraf Tiruan & Pemrogramannya Menggunakan Matlab". Yogyakarta: Andi
- Sofyan, Assauri. 1984. "Teknik dan Metode Peramalan". Jakarta : Penerbit Fakultas Ekonomi Universitas Indonesia
- Sun, Z.L., Choi, T.M., Au, K.F., dan Yu, Y. 2008. "Sales Forecasting using Extreme Learning Machine with Application in Fashion Retailing". *Elsevier Decision Support Systems* 46(2008) 411-419
- Umi Mahdiyah, M. Isa Irawan, Elly Matul Imah . 2015. "Integrating Data Selection and Extreme Learning Machine for Imbalanced Data". *Journal of Elsevier*. Vol. 59(2015): pp 221-229.
- Imah, Elly Matul, Jatmiko Wisnu, T. Basaruddin, "Adaptive Multilayer Generalized Learning Vector Quantization (AMGLVQ) as new algorithm with integrating feature extraction and classification for Arrhythmia heartbeats classification". *Systems, Man, and Cybernetics (SMC)*, 2012 IEE Internasional Conference: pp150-155