

## Hybrid Extreme Learning Machine dan Firefly Algorithm untuk Meramalkan Nilai Tukar Rupiah terhadap Dolar

Ilham Ramadhani<sup>1</sup>, Auli Damayanti<sup>1,\*</sup> & Edi Winarko<sup>1</sup>

<sup>1</sup>Mathematics Department, Faculty of Science and Technology, Universitas Airlangga

\*Corresponding author: auli-d@fst.unair.ac.id

**Abstract.** Every country has a currency as a medium of exchange and the movement of its exchange rate can affect the economy of the country. In Indonesia, since the freely floating exchange rates system has been applied in August 1997, the value of rupiah currency in the foreign exchange market can change at any time. Considering the massive impacts of exchange rate fluctuation on the economy, then forecasting the exchange rate of rupiah against the US dollar is important to help Indonesia's economic growth. The aims of this thesis is to predict the estimated exchange rate of rupiah against the US dollar in the future by using hybrid artificial neural network extreme learning machine (ELM) method and firefly algorithm (FA). In the training process, ELM-FA hybrid has a role to obtain the best weight and bias. The weight and bias that obtained will be used for forecasting and to know the success rate of the training process, the validation test process is required. Based on the implementation of program and simulation for some parameter values on the exchange rate data from Jan 2015 until Jan 2018, with four input and hidden nodes, and one output node, obtained the smallest MSE of the training is 0.000480513 with MSE of the testing is 0.0000854107. The relatively small MSE value indicates that ELM-FA network is able to recognize the data pattern well and able to predict the test data well.

**Keywords:** *extreme learning machine, firefly algorithm, forecasting, rupiah exchange rate.*

### 1 Pendahuluan

Prediksi atau peramalan merupakan salah satu hal yang penting dilakukan sebagai upaya mengetahui perkiraan keadaan di masa depan, sebagai contoh meramal nilai tukar mata uang asing. Setiap negara memiliki mata uang sebagai alat tukar dan pergerakan nilai tukarnya dapat mempengaruhi perekonomian suatu negara, misalnya mempengaruhi harga barang yang dapat memicu terjadinya inflasi. Di Indonesia, semenjak diberlakukannya sistem nilai tukar mengambang bebas (*freely floating exchange rates*) pada Agustus 1997, nilai mata uang rupiah di bursa valuta asing bisa berubah setiap waktu. Kurs (nilai tukar) mengambang bebas adalah keadaan dimana kurs ditentukan semata-mata oleh penawaran dan permintaan tanpa adanya intervensi pemerintah. Jika pemerintah mengintervensi pasaran valuta asing dengan tujuan mempengaruhi kursnya, maka sistem demikian disebut mengambang terkendali. Perubahan kurs dapat berupa depresiasi dan apresiasi. Kalau harga mata uang suatu negara turun relatif terhadap mata uang asing lainnya, dikatakan bahwa mata uang negara itu mengalami depresiasi

sedangkan mata uang asingnya mengalami apresiasi [1]. Fenomena yang sering terjadi berhubungan dengan kurs mata uang yaitu fluktuasi nilai mata uang yang tidak menentu. Sebab-sebab yang mempengaruhi tidak stabilnya nilai tukar uang, yaitu faktor politik (kontrol terhadap arus modal dan *spread* kurs valas) dan ekonomi makro fundamental (inflasi, suku bunga, situasi neraca pembayaran, trend pertumbuhan pendapatan nasional, pengeluaran pemerintah, dan perubahan jumlah uang beredar) [2].

Amerika Serikat dipandang sebagai negara maju dengan Dolar Amerika Serikat (USD) sebagai mata uangnya. Melalui mekanisme transmisi, inflasi serta suku bunga domestik bisa turun ke tingkat yang rendah. Sebaliknya, dengan menguatnya dolar Amerika Serikat belakangan, nilai rupiah merosot dan berpotensi mendorong inflasi. Pergerakan nilai tukar yang fluktuatif ini mempengaruhi perilaku masyarakat dalam memegang uang, selain faktor-faktor yang lain seperti tingkat suku bunga dan inflasi. Kondisi ini didukung oleh laju inflasi yang meningkat tajam dan menurunnya kepercayaan masyarakat terhadap perbankan nasional. Ketidakstabilan nilai tukar mempengaruhi arus modal atau investasi dan perdagangan internasional. Indonesia sebagai negara yang banyak mengimpor bahan baku industri mengalami dampak dan ketidakstabilan kurs ini, yang dapat dilihat dari melonjaknya biaya produksi sehingga menyebabkan harga barang-barang milik Indonesia mengalami peningkatan. Dengan melemahnya rupiah menyebabkan perekonomian Indonesia menjadi goyah dan dilanda krisis ekonomi serta kepercayaan terhadap mata uang dalam negeri [3]. Kondisi tersebut semakin membuat nilai tukar dolar Amerika Serikat terhadap rupiah semakin tinggi, karena sebagian besar transaksi internasional di Indonesia menggunakan dolar Amerika Serikat [4].

Mengingat besarnya dampak dari fluktuasi nilai tukar terhadap perekonomian, maka peramalan nilai tukar rupiah terhadap dolar Amerika Serikat penting dilakukan untuk membantu pertumbuhan ekonomi Indonesia. Meramalkan valas (nilai tukar mata uang asing) merupakan strategi yang amat penting bagi suksesnya usaha bisnis internasional. Ketidaktepatan peramalan atau proyeksi valas dapat melenyapkan peluang merebut laba dari transaksi internasional. Dengan demikian, meramal valas merupakan kunci bagi pengambilan keputusan yang melibatkan transfer dana dari satu mata uang ke mata uang lain dalam suatu periode waktu tertentu. Pergerakan kurs valas tergantung dari interaksi berbagai faktor secara simultan. Bagaimana berbagai faktor ini mempengaruhi satu sama lain dan bagaimana mereka mempengaruhi pergerakan valas relatif sulit dikuantifikasi maupun diramal. Kurs valas dapat saja bereaksi amat tajam akibat suatu peristiwa yang tidak terduga sebelumnya sehingga menjangkirbalikkan berbagai teori dan ramalan pada periode tersebut [2]. Untuk mendapatkan hasil yang akurat dan stabil diperlukan sebuah metode yang tepat. Metode yang ada pada *Artificial Neural Networks*, dapat digunakan untuk mempelajari pola dari data historis yang didapatkan [5].

Banyak metode *Artificial Neural Networks* atau Jaringan Saraf Tiruan (JST) yang telah diterapkan dalam peramalan memiliki laju pembelajaran (*learning speed*) yang rendah sehingga waktu komputasi yang dibutuhkan cenderung lama. Hal tersebut disebabkan oleh penggunaan algoritma pelatihan berbasis gradien dan parameter yang digunakan dalam jaringan ditentukan secara iteratif. Metode pelatihan baru dalam JST yang disebut *Extreme Learning Machine* (ELM) diusulkan [6] untuk mengatasi laju pembelajaran yang rendah. ELM memilih secara acak bobot masukan dan bias pada lapisan tersembunyi untuk proses pelatihan dan bobot keluaran diperoleh melalui komputasi. Kinerja metode ELM untuk kasus peramalan lebih baik dibandingkan dengan metode *Backpropagation* dengan nilai *error* yang dihasilkan adalah 0.01100 pada ELM dan 0.031933 pada *Backpropagation* [7].

Dalam penelitian ini diaplikasikan ELM yang merupakan metode dari JST pada peramalan nilai tukar rupiah terhadap dolar Amerika Serikat. ELM merupakan jaringan saraf tiruan *feedforward* dengan satu *hidden layer* atau lebih dikenal dengan istilah *single hidden layer feedforward neural network* (SLFNs). Metode ELM mempunyai kelebihan dalam *learning speed*, serta mempunyai tingkat akurasi yang lebih baik dibandingkan dengan metode konvensional seperti *Moving Average* dan *Exponential Smoothing*. Sehingga dengan menerapkan ELM diharapkan mampu menghasilkan ramalan di masa depan dengan baik [6].

*Firefly algorithm* (FA) merupakan algoritma yang terinspirasi dari perilaku berkedipnya cahaya kunang-kunang dan cara komunikasi kunang-kunang melalui cahaya yang dimilikinya [8]. Di dalam FA, fungsi tujuan pada permasalahan optimasi yang diberikan berhubungan dengan kerdipan cahaya atau intensitas cahaya yang membantu kawanan kunang-kunang untuk bergerak ke lokasi yang lebih cerah (memiliki daya tarik lebih) untuk memperoleh solusi yang lebih baik. Dalam praktiknya, FA ini konvergen sangat cepat pada iterasi yang kurang dari 80 dan jumlah populasi kunang-kunang yang kurang dari 50, seperti yang telah dijelaskan dalam beberapa penelitian [9].

Pada bidang kecerdasan buatan terdapat istilah *swarm intelligence* yang diartikan sebagai desain algoritma yang terinspirasi oleh perilaku sosial kolektif koloni serangga dan koloni binatang. FA atau algoritma kunang-kunang merupakan salah satu dari *swarm intelligence* tersebut. FA memang jauh lebih sederhana baik dalam konsep maupun implementasi. Selain itu *firefly algorithm* dapat mengungguli algoritma konvensional lainnya seperti *genetic algorithm* untuk memecahkan banyak masalah optimasi.

Dengan adanya kekurangan dan kelebihan yang ada pada JST dan FA ini, maka menarik untuk dilakukan pengombinasian (*hybrid*) jaringan saraf tiruan metode ELM dan FA pada proses pelatihan jaringan, agar pencarian bobot dan bias dalam proses pelatihannya menjadi lebih cepat. Dengan demikian setelah proses pelatihan berlangsung, diperoleh

solusi yang lebih baik sehingga akurat untuk memprediksi nilai tukar rupiah terhadap dolar Amerika Serikat.

## 2 Nilai Tukar (Kurs) dan Bursa Valuta Asing

Kurs atau nilai tukar valuta asing adalah harga mata uang negara asing dalam satuan mata uang domestik. Sebagai contoh, harga mata uang poundsterling Inggris dalam satuan dolar Amerika adalah \$1,80. Bagi penduduk Inggris, harga dolar Amerika adalah  $\text{£}1/\text{\$}1,80 = \text{£}0,56$ . Demikian pula, pada saat tertentu, ada kurs tertentu yang berlaku antara mata uang negara satu dengan mata uang negara lainnya di dunia [1]. Nilai tukar (*exchange rates*) menunjukkan banyaknya unit mata uang yang dapat dibeli atau ditukar dengan satu satuan mata uang lain. *Exchange rates* tampak dalam surat kabar/seksi keuangan setiap hari. Banyaknya US\$ yang diperlukan untuk membeli satu unit mata uang asing disebut *direct quotation*, sedangkan banyaknya mata uang asing yang dapat dibeli dengan satu dolar Amerika disebut *indirect quotation*. Sudah menjadi suatu kesepakatan umum bahwa nilai tukar mata uang asing dinyatakan dalam *dolar basis* [10].

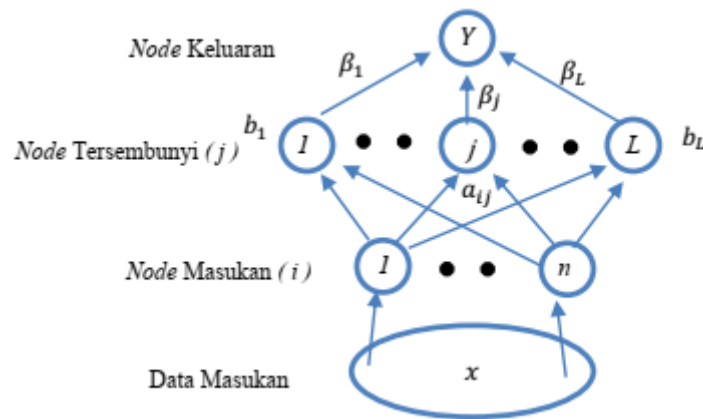
Bursa (Pasar) valuta asing adalah tempat berlangsungnya perdagangan berbagai mata uang negara yang berbeda; di sinilah nilai tukar ditentukan. Pada umumnya, valuta asing diperdagangkan oleh bank-bank serta perusahaan-perusahaan yang berspesialisasi pada bisnis tersebut [1]. Bursa valuta asing yang biasa disebut pula *foreign exchange market* yang diartikan sebagai lembagapasar di mana orang dapat memperoleh fasilitas-fasilitas untuk melaksanakan pembayaran kepada penduduk negara lain atau menerima pembayaran dari penduduk negara lain. Tidak sedikit pula yang mengartikan bursa valuta asing sebagai tempat di mana permintaan dan penawaran valuta asing dipertemukan [11].

## 3. *Extreme Learning Machine*

*Extreme Learning Machine* (ELM) merupakan metode pelatihan baru dari jaringan saraf tiruan. ELM merupakan jaringan saraf tiruan *feedforward* dengan *single hidden layer* atau biasa disebut *single-hidden layer feedforward neural networks* (SLFNs). Metode pelatihan ELM dibuat untuk mengatasi kelemahan-kelemahan dari jaringan saraf tiruan *feedforward* terutama dalam hal *learning speed*. Peneliti [6] mengemukakan dua alasan mengapa JST *feedforward* mempunyai *learning speed* rendah. Pertama, menggunakan *slow gradient-based learning algorithm* untuk melakukan *training*. Kedua, semua parameter pada jaringan ditentukan secara *iterative* dengan menggunakan metode pelatihan tersebut. Pada pelatihan dengan menggunakan *conventional gradient-based learning algorithm* seperti *backpropagation* (BP), semua parameter pada JST *feedforward* harus ditentukan secara iteratif. Parameter yang dimaksud adalah *input weight* dan *hidden bias*. Parameter-parameter tersebut juga saling berhubungan antara

layer yang satu dengan yang lain, sehingga membutuhkan *learning speed* yang lama dan sering terjebak pada *local minimal*. Sedangkan pada ELM parameter-parameter seperti *input weight* dan *hidden bias* dipilih secara random, sehingga ELM memiliki *learning speed* yang cepat dan mampu menghasilkan *good generalization performance*.

Pada **Gambar 1** digambarkan arsitektur jaringan ELM yang merupakan jaringan saraf tiruan *feedforward* dengan *single hidden layer*. Pada jaringan tersebut, selain terdapat *node-node input*, tersembunyi (*hidden*), dan *output* juga terdapat bias yang diberikan pada *node-node* tersembunyi dilambangkan dengan  $b$ . Bobot antara *node input* dan *node hidden* dilambangkan dengan  $a$ . Jaringan ELM memiliki  $n$  *node input* dengan  $L$  *node hidden* dan sebuah *node output*. Neuron *input* dilambangkan dengan  $X$ , *node hidden* dilambangkan dengan  $G$ , dan *node output* dilambangkan dengan  $Y$ . Sedangkan untuk bobot antara  $G$  dan  $Y$  dilambangkan dengan  $\beta$ .



**Gambar 1.** Arsitektur ELM

Untuk menghitung *output* dari *hidden layer* dapat digunakan persamaan (1) :

$$G(a_j, x, b_j) = g(\sum_{i=1}^n a_{ij}x_i + b_j), \quad j = 1, \dots, L \quad (1)$$

dengan

$L$  = jumlah neuron *hidden*

$n$  = jumlah *input* neuron

$a_j = (a_{1j}, a_{2j}, \dots, a_{nj})$

$x = (x_1, x_2, \dots, x_n)$

Sedangkan untuk menghitung output jaringan dapat digunakan persamaan (2) :

$$Y = \sum_{j=1}^L \beta_j G(a_j, x, b_j) \quad (2)$$

Untuk jumlah pola data sebanyak  $p$  dan jumlah neuron *hidden* sebanyak  $L$ , dapat disusun sebuah matriks  $H$  yang beranggotakan keluaran dari lapisan tersembunyi yang berukuran  $p \times L$ . Matriks  $H$  tersebut dapat dinyatakan dalam persamaan (3) :

$$H = \begin{bmatrix} G(a_1, x^1, b_1) & G(a_2, x^1, b_2) & \dots & G(a_L, x^1, b_L) \\ \vdots & \vdots & & \vdots \\ G(a_1, x^p, b_1) & G(a_2, x^p, b_2) & \dots & G(a_L, x^p, b_L) \end{bmatrix} \quad (3)$$

dengan  $x^p = (x_1, x_2, \dots, x_n)$  adalah data input pola ke  $p$ .

Proses pelatihan jaringan saraf tiruan metode ELM adalah sebagai berikut (**Sun, dkk., 2008**):

1. Input data pelatihan yang telah dinormalisasi sebagai *node* masukan  $(x_1, x_2, \dots, x_n)$  dan tentukan fungsi aktivasi serta jumlah neuron pada lapisan tersembunyi.
2. Inisialisasi bobot masukan ( $a_i$ ) dan bias ( $b_j$ ) secara acak.
3. Hitung setiap keluaran dari *node* pada lapisan tersembunyi dan dilambangkan dengan  $(a_j, x, b_j)$ . Kemudian disusunlah sebuah matriks  $H$  yang beranggotakan semua keluaran dari *node* pada lapisan tersembunyi  $G(a_j, x, b_j)$ .
4. Bobot akhir ( $\beta_j$ ) yang menghubungkan lapisan tersembunyi dan lapisan keluaran dihitung dengan persamaan (4):

$$\beta = H^+ T \quad (4)$$

dengan  $H^+$  merupakan moore penrose generalized invers dari matriks  $H$  dan  $T$  merupakan vektor target.

5. Hitung semua keluaran di *node* pada lapisan keluaran dengan persamaan (2).
6. Menghitung nilai *Mean Square Error* (MSE).
7. Memeriksa kondisi penghentian. Untuk memeriksa kondisi penghentian dapat dilakukan dengan dua cara, yaitu:
  - i. Membatasi jumlah iterasi (*epoch*) yang diinginkan
  - ii. Membatasi *error*
8. Jika *error* atau iterasi belum terpenuhi, maka lakukan kembali langkah 2 dan seterusnya.

Proses uji validasi jaringan saraf tiruan metode ELM adalah sebagai berikut [12]:

1. Input data pengujian yang telah dinormalisasi sebagai *node* masukan  $(x_1, x_2, \dots, x_n)$ .
2. Inisialisasi bobot dan bias yang diperoleh dari algoritma pelatihan.

3. Hitung setiap keluaran dari *node* pada lapisan tersembunyi dan dilambangkan dengan  $(a_j, x, b_j)$ .
4. Hitung semua keluaran di *node* pada lapisan keluaran dengan persamaan (2).

#### 4. *Firefly Algorithm*

Menurut [13], *Firefly Algorithm* (FA) terinspirasi oleh perilaku sosial dan cara komunikasi sekelompok kunang-kunang (*firefly*) melalui cahaya di bagian ekornya. Sebagian besar kunang-kunang menghasilkan kilatan cahaya pendek dan berirama, yang memiliki pola unik pada setiap spesies. Cahaya berkilau kunang-kunang memiliki dua fungsi, yaitu: menarik kunang-kunang lain untuk dijadikan pasangan dan menjebak calon mangsa.

FA dikembangkan oleh Xin-She Yang pada tahun 2007, dan FA memiliki tiga aturan berikut [8]:

1. Semua kunang-kunang adalah *unisex* sehingga setiap kunang-kunang akan tertarik satu sama lain dan tidak memilih jenis kelamin.
2. Daya tarik (*attractiveness*) kunang-kunang bersifat proposional dengan intensitas cahaya (*light intensity*) yang dimilikinya. Kunang-kunang yang memiliki intensitas cahaya rendah (redup) akan tertarik dan bergerak ke kunang-kunang yang memiliki intensitas cahaya yang lebih tinggi (terang). Jika tidak ada kunang-kunang bercahaya lebih terang dari dirinya, maka kunang-kunang tersebut akan bergerak secara acak; dan
3. Intensitas cahaya kunang-kunang ditentukan oleh fungsi objektif. Untuk masalah maksimasi, intensitas cahaya proporsional dengan nilai fungsi objektif.

##### A. Intensitas Cahaya dan Keatraktifan *Firefly*

*Attractiveness* (daya tarik) seekor kunang-kunang proposional dengan intensitas cahayanya yang dilihat oleh kunang-kunang lain. Fungsi keatraktifan [8] dirumuskan dengan persamaan (5):

$$\beta(r) = \beta_0 e^{-\gamma r^2} \quad (5)$$

dengan  $\beta(r)$  adalah *attractiveness* kunang-kunang pada jarak  $r$ ,  $\beta_0$  adalah *attractiveness* kunang-kunang pada  $r = 0$ ,  $\gamma$  adalah koefisien daya serap cahaya (*light absorption*), dan  $r$  adalah jarak antara dua kunang-kunang.

##### B. Jarak antar *Firefly*

Jarak antara dua kunang-kunang  $i$  dan  $j$  pada posisi koordinat  $x_i$  dan  $x_j$  adalah jarak euclidean yang dirumuskan dengan persamaan (6) :

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (6)$$

dengan  $x_{i,k}$  adalah komponen ke- $k$  dari *firefly* ke- $i$  ( $x_i$ ) dan  $x_{j,k}$  adalah komponen ke- $k$  dari *firefly* ke- $j$  ( $x_j$ ), dan  $d$  adalah banyaknya komponen dari individu *firefly*.

### C. Pergerakan *Firefly*

Gerakan kunang-kunang  $i$  yang tertarik ke kunang-kunang  $j$  (yang lebih terang atau memiliki *attractiveness* lebih tinggi) dirumuskan dengan persamaan (7):

$$x_i(\text{baru}) = x_i + \beta_0 e^{-\gamma r_{ij}^2} (x_j - x_i) + \alpha \left( \text{rand} - \frac{1}{2} \right) \quad (7)$$

dengan  $\beta_0 e^{-\gamma r_{ij}^2} (x_j - x_i)$  adalah perpindahan *firefly* yang terjadi karena adanya daya tarik (keatraktifan *firefly*) sedangkan bagian ketiga dalam penjumlahan tersebut adalah proses pengacakan parameter  $\alpha$  dan *rand* adalah fungsi pembangkit bilangan real secara *random* berdistribusi *uniform* pada interval  $[0,1]$ . Pada umumnya, digunakan  $\beta_0 = 1$ ,  $\alpha \in [0,1]$ , dan  $\gamma \in [0, \infty)$ .

*Firefly* terbaik yakni *firefly* yang memiliki intensitas cahaya paling tinggi. *Firefly* tersebut juga melakukan pergerakan secara random yaitu dengan persamaan (8):

$$x_i(\text{baru}) = x_i + \alpha \left( \text{rand} - \frac{1}{2} \right) \quad (8)$$

Langkah-langkah dasar *Firefly Algorithm* adalah sebagai berikut [8]:

1. Input parameter *Firefly Algorithm*.
2. Membangkitkan populasi awal berupa bilangan real yang diambil secara *random* sebanyak  $m$  *firefly*.
3. Hitung intensitas cahaya tiap *firefly*  $I(x)$  berdasarkan nilai fungsi tujuan  $f(x)$ .
4. Membandingkan intensitas cahaya tiap *firefly* dengan *firefly* lainnya. Apabila terdapat *firefly* yang memiliki intensitas cahaya lebih besar, lakukan *update firefly* dengan menggunakan persamaan pergerakan *firefly*.
5. Menentukan *firefly* terbaik. *Firefly* dengan intensitas paling tinggi merupakan *firefly* terbaik.
6. Melakukan proses pergerakan kepada *firefly* terbaik dan menggabungkannya dengan *firefly* yang lain untuk menjadi populasi awal pada iterasi selanjutnya.
7. Jika batas iterasi dipenuhi, maka proses berhenti. Jika tidak, maka proses kembali ke langkah 3



## 5. Peramalan Menggunakan ELM-FA

Langkah-langkah yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Studi pustaka mengenai masalah yang berkaitan dengan nilai tukar rupiah terhadap dolar Amerika Serikat, peramalan (*forecasting*), jaringan saraf tiruan metode *extreme learning machine* (ELM), dan *firefly algorithm* (FA).
2. *Hybrid* jaringan saraf tiruan metode *extreme learning machine* dan *firefly algorithm* untuk meramalkan nilai tukar rupiah terhadap dolar Amerika Serikat dengan langkah-langkah sebagai berikut:
  - i. Menghimpun data kurs (nilai tukar) rupiah terhadap dolar Amerika Serikat. Data yang dihimpun bersumber dari [www.bi.go.id](http://www.bi.go.id). Komposisi pembagian data untuk pelatihan (*training*) dan uji validasi adalah sebagai berikut:
    - 70% dari total data digunakan sebagai data pelatihan (*training*).
    - 30% dari total data digunakan sebagai data uji validasi.
  - ii. Melakukan proses normalisasi data kurs ke interval (0,1). Proses tersebut untuk mengurangi kompleksitas data, dan memudahkan dalam memodifikasi data.
  - iii. Membuat rancangan pola data yang akan digunakan sebagai nilai *input* dalam jaringan ELM-FA. Karena data kurs yang diperoleh merupakan data kurs harian kecuali hari sabtu dan minggu, maka jumlah *node* masukan yang dipilih sebanyak empat. Jumlah *node* masukan tersebut mempresentasikan jumlah hari dalam satu minggu dengan target hari ke-5. Format pola data untuk pelatihan (509 pola data) disajikan pada **Tabel 1**.

**Tabel 1** Format Pola Data Untuk Pelatihan

Pola	$x_1$	$x_2$	$x_3$	$x_4$	Target
1	Data ke-1	Data ke-2	Data ke-3	Data ke-4	Data ke-5
2	Data ke-2	Data ke-3	Data ke-4	Data ke-5	Data ke-6
3	Data ke-3	Data ke-4	Data ke-5	Data ke-6	Data ke-7
⋮	⋮	⋮	⋮	⋮	⋮
509	Data ke-509	Data ke-510	Data ke-511	Data ke-512	Data ke-513

- iv. Mendesain arsitektur jaringan saraf tiruan yang terdiri dari *input layer*, *hidden layer*, dan *output layer*. Rancangan jumlah *neuron* pada setiap lapisan adalah sebagai berikut:
  - a. Jumlah *neuron* yang digunakan pada *input layer* sebanyak empat.
  - b. Jumlah *neuron* yang digunakan pada *hidden layer* sama dengan jumlah *neuron* yang digunakan pada *input layer*
  - c. Jumlah *neuron* yang digunakan pada *output layer* sebanyak satu.

- v. Melakukan proses pelatihan (*training*) metode ELM-FA untuk memperoleh nilai bobot dan bias.
  - a. Masukkan data pelatihan (*training*) yang telah dinormalisasi.
  - b. Inisiasi nilai-nilai parameter yang digunakan pada jaringan, yaitu banyaknya *firefly*,  $\alpha$ ,  $\beta_0$ , maksimum iterasi, dan batas MSE.
  - c. Membangkitkan populasi awal pada *firefly*. Menentukan populasi awal dengan membangkitkan bilangan real secara *random* pada interval (-1,1) sebanyak jumlah *firefly*.
  - d. Konversi individu *firefly* dalam FA menjadi bobot masukan ( $a$ ) dan bias ( $b$ ) dalam ELM.
  - e. Menghitung keluaran dari *node* pada lapisan tersembunyi. Fungsi aktivasi yang digunakan pada ELM adalah *sigmoid biner* [14].
  - f. Menghitung bobot akhir keluaran ( $\beta$ ).
  - g. Menghitung keluaran jaringan ( $Y$ ).
  - i. Memeriksa *stopping condition*. Terdapat dua kondisi *stopping condition*, yaitu jumlah iterasi sudah mencapai batas maksimum atau nilai *error* (MSE) pada pelatihan jaringan sudah terpenuhi.
  - j. Jika *error* atau jumlah iterasi belum terpenuhi, maka proses pelatihan lanjut ke langkah (2.e.x). Jika *error* atau jumlah iterasi telah terpenuhi maka simpan individu *firefly* dan  $\beta$  yang merupakan solusi, kemudian lanjut ke langkah (vi).
  - k. Menghitung nilai *fitness* dari tiap individu *firefly* menggunakan persamaan:

$$f(x) = \frac{1}{1 + MSE(x)}$$

- l. Transformasi nilai *fitness* menjadi nilai intensitas cahaya *firefly*. Intensitas cahaya sebanding dengan nilai *fitness*.
- m. Membandingkan intensitas cahaya *firefly* ke- $i$  dengan *firefly* ke- $j$  seperti berikut:
  - Jika intensitas cahaya *firefly* ke- $i$  lebih besar dari *firefly* ke- $j$ , ulangi langkah ini dengan  $j = j + 1$ .
  - Jika intensitas cahaya *firefly* ke- $i$  lebih kecil dari *firefly* ke- $j$ , maka hitung jarak *firefly* ke- $i$  ke *firefly* ke- $j$ , kemudian hitung nilai keatraktifan *firefly* dan lakukan pergerakan dari *firefly* ke- $i$  menuju *firefly* ke- $j$ , kemudian ulangi langkah ini dengan  $j = j + 1$ .
 Ketika  $j$  lebih besar dari jumlah *firefly*, maka lanjut ke langkah  $n$ .
- n. Ulangi langkah  $m$  dengan  $i = i + 1$  sampai semua *firefly* dibandingkan.
- o. Tentukan *firefly* terbaik yaitu *firefly* dengan intensitas cahaya paling besar. Setelah itu lakukan pergerakan pada *firefly* terbaik, kemudian lakukan kembali langkah o.

- vi. Melakukan uji validasi. Format data untuk validasi disajikan pada **Tabel 2**.
  - a. Masukkan data untuk uji validasi yang telah dinormalisasi.
  - b. Masukkan bobot dan bias yang diperoleh dari proses pelatihan.
  - c. Menghitung keluaran dari jaringan ( $Y$ ) dan MSE.
- vii. Melakukan denormalisasi data.

**Tabel 2** Format Pola Data Untuk Uji Validasi

Pola	$x_1$	$x_2$	$x_3$	$x_4$	Target
1	Data ke-514	Data ke-515	Data ke-516	Data ke-517	Data ke-518
2	Data ke-515	Data ke-516	Data ke-517	Data ke-518	Data ke-519
3	Data ke-516	Data ke-517	Data ke-518	Data ke-519	Data ke-520
⋮	⋮	⋮	⋮	⋮	⋮
217	Data ke-730	Data ke-731	Data ke-732	Data ke-733	Data ke-734

- 3. Membuat program *hybrid* jaringan saraf tiruan metode *extreme learning machine* dan *fireflyalgorithm*.
- 4. Mengimplementasikan program untuk peramalan nilai tukar rupiah terhadap dolar Amerika Serikat .

## 6. Hasil dan Pembahasan

Pada penelitian ini digunakan bahasa pemrograman C++ untuk melakukan semua proses yang telah dijelaskan pada subbab sebelumnya. Kemudian dilakukan simulasi prediksi peramalan nilai tukar rupiah terhadap dolar Amerika Serikat. Langkah pertama yang diminta program ialah memasukkan beberapa parameter yaitu jumlah maksimum iterasi, nilai batas MSE, keaktraktifan awal, koefisien udara, koefisien *random*, dan jumlah *firefly*.

Nilai keaktraktifan awal yang dipilih untuk simulasi ini sebesar 1, dan batas MSE sebesar 0.0001. Beberapa variasi nilai parameter yang digunakan untuk memperoleh nilai MSE terkecil pada proses pelatihan disajikan pada **Tabel 3**, **Tabel 4**, dan **Tabel 5**. Validasi dengan individu *firefly* sebanyak 3 disajikan pada **Tabel 3**.

**Tabel 3** Hasil Pelatihan dan Uji Validasi untuk Beberapa Nilai Parameter dengan *popsize* = 3

No.	Koefisien <i>random</i>	Koefisien udara	Maks iterasi	MSE terkecil	Iterasi Berhenti	MSE Uji
1	0.01	0.01	10	0.000566796	10	0.0000905586
2			200	0.000512566	200	0.0000857925
3		0.2	10	0.000571375	10	0.0000914413
4			200	0.000514431	200	0.000086081
5		0.5	10	0.000559643	10	0.0000895854
6			200	0.000558039	200	0.0000899909
7	0.2	0.01	10	0.000527438	10	0.0000874421
8			200	0.000486166	200	0.0000861531
9		0.2	10	0.000576913	10	0.0000936482
10			200	0.00050587	200	0.0000855961
11		0.5	10	0.000594398	10	0.000109479
12			200	0.000508325	200	0.0000842686
13	0.5	0.01	10	0.000549267	10	0.0000868391
14			200	0.00050463	200	0.0000835798
15		0.2	10	0.000554622	10	0.000093351
16			200	0.00049644	200	0.000084138
17		0.5	10	0.000970305	10	0.000149023
18			200	0.00188459	200	0.000523052

**Tabel 4** Hasil Pelatihan dan Uji Validasi untuk Beberapa Nilai Parameter dengan *popsize* = 10

No.	Koefisien <i>random</i>	Koefisien udara	Maks Iterasi	MSE terkecil	Iterasi Berhenti	MSE Uji
1	0.01	0.01	10	0.000538022	10	0.000089694
2			200	0.000516493	200	0.0000849318
3		0.2	10	0.000513193	10	0.0000904561
4			200	0.000516851	200	0.0000859038
5		0.5	10	0.000524063	10	0.000084505
6			200	0.000520434	200	0.0000845381

No.	Koefisien <i>random</i>	Koefisien udara	Maks Iterasi	MSE terkecil	Iterasi Berhenti	MSE Uji	
7	0.2	0.01	10	0.000523433	10	0.0000850836	
8			200	0.000503482	200	0.000084779	
9		0.2	10	0.000512076	10	0.0000908442	
10			200	0.000502218	200	0.0000862579	
11		0.5	0.5	10	0.000521708	10	0.000088783
12				200	0.000494469	200	0.0000894164
13	0.5	0.01	10	0.000527498	10	0.0000849267	
14			200	0.000517428	200	0.0000857581	
15		0.2	10	0.000521567	10	0.0000868285	
16			200	0.00051625	200	0.0000852438	
17		0.5	0.5	10	0.000536887	10	0.000086073
18				200	0.000516104	200	0.0000868335

**Tabel 5** Hasil Pelatihan dan Uji Validasi untuk Beberapa Nilai Parameter dengan *popsize* = 20

No.	Koefisien <i>random</i>	Koefisien udara	Maks Iterasi	MSE terkecil	Iterasi Berhenti	MSE Uji	
1	0.01	0.01	10	0.00049588	10	0.0000863536	
2			200	0.000486444	200	0.0000854881	
3		0.2	10	0.00052302	10	0.0000844497	
4			200	0.000521011	200	0.0000844467	
5		0.5	0.5	10	0.000519636	10	0.0000846075
6				200	0.000518054	200	0.0000854692
7	0.2	0.01	10	0.000517768	10	0.0000885977	
8			200	0.000494787	200	0.0000891541	
9		0.2	0.2	10	0.000515993	10	0.0000855428
10				200	0.000516314	200	0.0000873433
11		0.5	0.5	10	0.000502455	10	0.0000866318
12				200	0.000480513	200	0.0000854107

No.	Koefisien <i>random</i>	Koefisien udara	Maks Iterasi	MSE terkecil	Iterasi Berhenti	MSE Uji
13	0.5	0.01	10	0.000508661	10	0.0000877784
14			200	0.000482172	200	0.00008416
15		0.2	10	0.000521808	10	0.0000864831
16			200	0.000514985	200	0.00008717
17		0.5	10	0.000539409	10	0.0000879365
18			200	0.000516516	200	0.0000863552

Setelah proses pelatihan dan uji validasi dijalankan dengan semua variasi nilai parameter, dapat diketahui bahwa MSE pelatihan terkecil dari ketiga variasi jumlah *firefly* sebesar 0.000480513. Nilai MSE tersebut diperoleh ketika nilai parameter koefisien *random* = 0.2, koefisien udara = 0.5, jumlah *firefly* = 20, dengan iterasi sebanyak 200. Sehingga nilai bobot dan bias yang diperoleh dari nilai-nilai parameter tersebut dapat digunakan selanjutnya untuk prediksi kurs masa mendatang. Nilai MSE uji validasi relatif kecil menunjukkan bahwa hasil pelatihan ELM-FA mampu memprediksi data uji dengan baik. Masing-masing nilai bobot dan bias optimal pelatihan dari ketiga variasi jumlah *firefly* disajikan pada **Tabel 6**.

**Tabel 6** *Firefly* Terbaik pada Proses Pelatihan

Jumlah <i>Firefly</i>		Bobot <i>input</i> ( $a_{ij}$ )				Bias ( $b$ )	Beta ( $\beta$ )
		$h_1$	$h_2$	$h_3$	$h_4$		
3	$x_1$	-0.5578	0.29479	0.639835	-1.31209	-1.09909	1.06698
	$x_2$	-0.77884	-0.02055	0.029552	-0.27233	-1.02821	13.2631
	$x_3$	-1.75665	-0.06592	-0.15412	0.023328	-1.61653	-15.5331
	$x_4$	-0.23052	0.262109	-0.12519	0.095633	-0.7477	-3.63348
10	$x_1$	-0.21019	0.311438	0.055783	0.440858	-0.06539	-6.3925
	$x_2$	0.241308	0.365007	0.675886	0.358912	-0.24	20.7487
	$x_3$	0.115124	0.291919	-0.71525	0.239801	0.399923	1.362
	$x_4$	0.282199	-0.35285	0.098394	-0.70263	-0.60476	-19.4183
	$x_1$	-0.19271	0.952337	0.191217	0.486552	-0.00041	7.97772
	$x_2$	0.108056	0.900936	0.767976	0.327668	-0.12664	9.14708

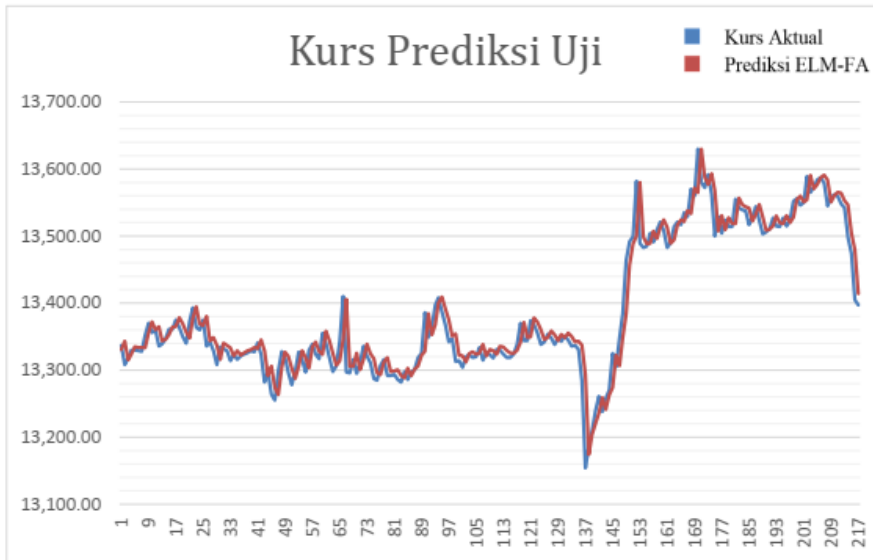
20	$x_3$	0.106962	0.274228	0.929668	-0.27735	-0.05123	-7.2355
	$x_4$	0.29582	-0.43579	-0.11609	-0.40556	-0.19156	-10.474

Berdasarkan nilai bobot dan bias tersebut, diperoleh nilai prediksi hasil uji validasi yang disajikan pada **Tabel 7**.

**Tabel 7** Nilai Keluaran Hasil Uji Validasi


Pola	Tanggal	Hasil Prediksi Data Uji (persentase <i>error</i> )			Fakta Kurs
		3 <i>firefly</i>	10 <i>firefly</i>	20 <i>firefly</i>	
1	8 Feb 17	Rp13327.6 (0.070%)	Rp13329.5 (0.056%)	Rp13330.6 (0.047%)	Rp13337
2	9 Feb 17	Rp13342.4 (0.258%)	Rp13342.7 (0.260%)	Rp13343.3 (0.265%)	Rp13308
3	10 Feb 17	Rp13314.2 (0.028%)	Rp13315.5 (0.018%)	Rp13315.2 (0.021%)	Rp13318
⋮	⋮	⋮	⋮	⋮	⋮
215	4 Jan 18	Rp13503.3 (0.217%)	Rp13502.8 (0.213%)	Rp13504.6 (0.227%)	Rp13474
216	5 Jan 18	Rp13477.4 (0.540%)	Rp13479.7 (0.557%)	Rp13479.8 (0.558%)	Rp13405
217	8 Jan 18	Rp13410 (0.097%)	Rp13407.8 (0.080%)	Rp13414.1 (0.127%)	Rp13397

Selanjutnya akan disajikan Grafik Nilai Keluaran Hasil Uji Validasi untuk ketiga variasi jumlah *firefly* pada **Gambar 2**, **Gambar 3**, dan **Gambar 4**. Grafik Nilai Keluaran Hasil Uji Validasi 3 *firefly* disajikan pada **Gambar 2**.




**Gambar 2** Grafik Nilai Keluaran Hasil Uji Validasi dengan *popsize* = 3

Selanjutnya, disajikan Grafik Nilai Keluaran Hasil Uji Validasi 10 *firefly* pada **Gambar 3**.



**Gambar 3** Grafik Nilai Keluaran Hasil Uji Validasi dengan *popsize* = 10





**Gambar 4** Grafik Nilai Keluaran Hasil Uji Validasi dengan  $popsiz e = 20$

Dapat diketahui dari beberapa pola data hasil uji validasi pada **Tabel 7**, nilai prediksi pada pola data ke-3 menunjukkan hasil mendekati nilai sebenarnya yaitu Rp13314.2 (3 *firefly*) dengan persentase *error* sebesar 0.028%, Rp13315.5 (10 *firefly*) dengan persentase *error* sebesar 0.018%, dan Rp13315.2 (20 *firefly*) dengan persentase *error* sebesar 0.021%. Hal ini menunjukkan bahwa kinerja ELM-FA dalam peramalan nilai kurs dapat dikatakan baik karena selisih *error* yang dihasilkan relatif kecil. Sehingga program ini dapat digunakan untuk peramalan nilai tukar rupiah selanjutnya. Rata-rata persentase *error* uji validasi yang dihasilkan oleh masing-masing *firefly* terbaik dari ketiga variasi jumlah *firefly*, yaitu 0.1395% (3 *firefly*), 0.1431% (10 *firefly*), dan 0.1379% (20 *firefly*).

Selanjutnya, dilakukan prediksi nilai tukar rupiah untuk lima hari akan datang yaitu tanggal 9, 10, 11, 12, dan 13 Januari 2018 menggunakan bobot dan bias optimal pelatihan (MSE pelatihan sebesar 0.000480513). Hasil prediksi disajikan pada **Tabel 8**.

Untuk memperoleh hasil prediksi pada tanggal 9 Januari 2018, digunakan data *input* kurs empat hari sebelumnya. Sedangkan hasil prediksi yang diperoleh pada tanggal 9 Januari 2018 digunakan untuk memprediksi kurs pada tanggal 10 Januari 2018. Sehingga untuk memprediksi kurs pada tanggal 13 Januari 2018 (lima hari akan datang), digunakan hasil prediksi kurs pada tanggal 9-12 Januari 2018 sebagai data *input* jaringan ELM.

**Tabel 8** Nilai Keluaran Hasil Prediksi

No.	Tanggal	Hasil Prediksi
1	9 Jan 18	Rp13404.5
2	10 Jan 18	Rp13411.1
3	11 Jan 18	Rp13415.6
4	12 Jan 18	Rp13419.8
5	13 Jan 18	Rp13424.1

## 7. Kesimpulan

Berdasarkan implementasi program dan simulasi untuk beberapa nilai parameter, diperoleh MSE pelatihan ELM-FA terkecil sebesar 0.000480513 dengan MSE uji validasi sebesar 0.0000854107. Nilai MSE relatif kecil menunjukkan bahwa jaringan ELM-FA mampu mengenali pola data dan mampu memprediksi data uji dengan baik. MSE pelatihan terkecil diperoleh ketika nilai parameter koefisien *random* = 0.2, koefisien udara = 0.5, jumlah *firefly* = 20, dengan iterasi sebanyak 200. Nilai bobot dan bias yang diperoleh dari nilai-nilai parameter tersebut tersebut cukup baik digunakan untuk prediksi kurs masamendatang.

## 8. Daftar Pustaka

- [1] Samuelson, P. A., dan Nordhaus, W. D., 1994, *Makroekonomi*, Edisi 14, Erlangga, Jakarta.
- [2] Kuncoro, M., 1996, *Manajemen Keuangan Internasional*, Edisi 1, BPFY-Yogyakarta, Yogyakarta.
- [3] Triyono, 2008, Analisis Perubahan Kurs Rupiah terhadap Dolar Amerika, *Jurnal Ekonomi Pembangunan*, Vol 9, 156-167.
- [4] Jauhari, D., Hanafi, A., Yuniarsa, M. F. A., Satria, A. R., Luqman, H., dan Cholissodin, I., 2016, Prediksi Nilai Tukar Rupiah terhadap US Dollar menggunakan Metode Genetic Programming, *Jurnal Teknologi Informasi dan Ilmu Komputer* 3(4) : 285.
- [5] Jauhari, D., Himawan, A., dan Dewi, C., 2016. Prediksi Distribusi Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation di PDAM Kota Malang. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 3(2), 85-89.
- [6] Huang, G.-B., Zhu, Q.-Y., dan Siew, C.-K., 2006, Extreme Learning Machine: Theory and Applications, *Neurocomputing*, 70, 489-501.

- [7] Khotimah, B. K., R., Eka M., dan Yulianarta, H., 2010, Kinerja Metode Extreme Learning Machine (ELM) pada Sistem Peramalan, *Jurnal SimanteC*, **Vol 1**, 186-191.
- [8] Yang, X. S., 2010, *Engineering Optimization: An Introduction with Metaheuristic Applications*, Willy & Sons Inc, New Jersey.
- [9] Apostolopoulos, T., dan Vlachos, A., 2011, Application of the Firefly Algorithm for Solving the Economic Emissions Load Dispatch Problem, *International Journal of Combinatorics*, **Vol 2011**, 23.
- [10] Sartono, A., 1996, *Manajemen Keuangan*, Edisi 3, BPFE-Yogyakarta, Yogyakarta.
- [11] Reksoprajitno, S., 1995, *Ekonomi Internasional: Pengantar Lalu-Lintas Pembayaran Internasional*, Edisi 2, Liberty Yogyakarta, Yogyakarta.
- [12] Sun, Z-L., Choi, T.-M., Au, K.-F., dan Yu, Y., 2008, Sales Forecasting using Extreme Learning Machine with Applications in Fashion Retailing, *Decision Support Systems*, **46**, 411-419.
- [13] Suyanto, 2017, *Swarm Intelligence Komputasi Modern untuk Optimasi dan Big Data Mining*, Edisi 1, Informatika Bandung, Bandung.
- [14] Albadr, M.A.A., dan Tiun, S., 2017, Extreme Learning Machine: A Review, *International Journal of Applied Engineering Research*, **Vol 12**, 4610-4623.