

Sistem Prediksi Harga Nilai Tukar Mata Uang Menggunakan *Elman Recurrent Neural Network* dengan Algoritma Genetika sebagai Metode Pembelajaran

Prediction System for Currency Exchange Rates Using Elman Recurrent Neural Network with Genetic Algorithms as Learning Methods

Ida Bagus Nyoman Pascima^{*1}, Sri Hartati²

^{1,2}Jurusan Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta
e-mail: ^{*1}ida.bgs.n@mail.ugm.ac.id, ²shartati@ugm.ac.id

Abstrak

Soft computing belakangan ini marak dipergunakan untuk membantu manusia seperti pada bidang peramalan, klasifikasi, *clustering* dan bidang lain. Pada bidang peramalan nilai tukar mata uang (*forex*), peramalan telah dilakukan dengan memanfaatkan Jaringan Saraf Tiruan (JST) seperti *Elman Recurrent Neural network* (ERNN). JST memerlukan proses *training* yang memakan waktu lama untuk memberikan peramalan yang akurat. Didorong permasalahan tersebut, penelitian ini berusaha memberikan alternatif solusi *training* agar waktu yang diperlukan semakin kecil tanpa mengurangi akurasi. Alternatif pembelajaran diusulkan dengan menggunakan Algoritma Genetika karena kemampuan generalisasi Algen mampu melakukan pencarian pada ruang pencarian yang luas. ERNN sendiri dipilih karena memiliki proses pembelajaran yang cepat dan cocok untuk data time series. ERNN memiliki *context layer* yang mengingat nilai t-1 yang mampu mempercepat proses pembelajaran.

Penelitian ini menghasilkan Algoritma Genetika sebagai alternatif metode pembelajaran JST yang mampu memberikan nilai *error* yang kecil dengan hasil prediksi yang lebih akurat. Selain itu dari sisi kecepatan pembelajaran, Algoritma Genetika mampu lebih cepat dibandingkan *Backpropagation Through Time* (BPTT) karena Algoritma Genetika memerlukan generasi yang sedikit walaupun tiap generasinya memerlukan waktu yang panjang. Namun kedua algoritma tidak dapat mencapai target error yang ditentukan dan berefek pada Dstat dari kedua algoritma belum mampu mencapai 60% sehingga belum dapat diterapkan pada industri

Kata kunci: *Forex, Elman Recurrent Neural Network, Algoritma Genetika, Backpropagation Through Time, Forecasting*

Abstract

Soft computing lately is used to help people in the case of forecasting, classification, clustering, etc. In the forex, forecasting can be used Artificial Neural Network (ANN) like Elman Recurrent Neural network (ERNN). ANN requires a long-time training process to provide accurate forecasting. Therefore, this research tries to provide alternative training solution for reducing time without reducing accuracy. So it can do trading or market analysis more precisely.

ERNN was chosen because of the fast and suitable learning process for time series data. ERNN has a context layer that remembers the t-1 value to accelerate the learning process. Alternative learning is proposed using the Genetic Algorithm (Algen) because Algen generalization is capable of performing searches on a large search space.

This research produced a Genetic Algorithm as an alternative method of learning ANN gives a more accurate prediction results than BPTT. Algen is also capable of faster than BPTT because Algen requires a little generation although each generation takes a long time. However, both algorithms can not achieve the specified target error which effect on Dstat from both algorithms has not been able to reach 60% so it can not be applied to industry.

Keywords: *Forex, Elman Recurrent Neural Network, Genetic Algorithm, Backpropagation Through Time, Forecasting*

1. Pendahuluan

Penerapan softcomputing telah banyak mempengaruhi perilaku kehidupan manusia. Pada penerapannya, softcomputing sangat membantu kehidupan manusia dalam berbagai bidang. Baik bidang kesehatan, keamanan, finansial dan lain sebagainya. Terdapat berbagai metode dalam softcomputing, salah satunya adalah Jaringan Saraf Tiruan (JST). Jaringan saraf Tiruan ini terinspirasi dari cara kerja otak manusia dimana sejumlah sel saraf yang terdiri dari Axon, dendrit synapse terhubung sehingga dapat memberikan solusi terhadap suatu permasalahan. JST bekerja menyerupai otak manusia dimana ketika sel saraf aktif akan menimbulkan sinyal ke axon yang melewati synapsis menuju sel saraf lain (Salman, 2011).

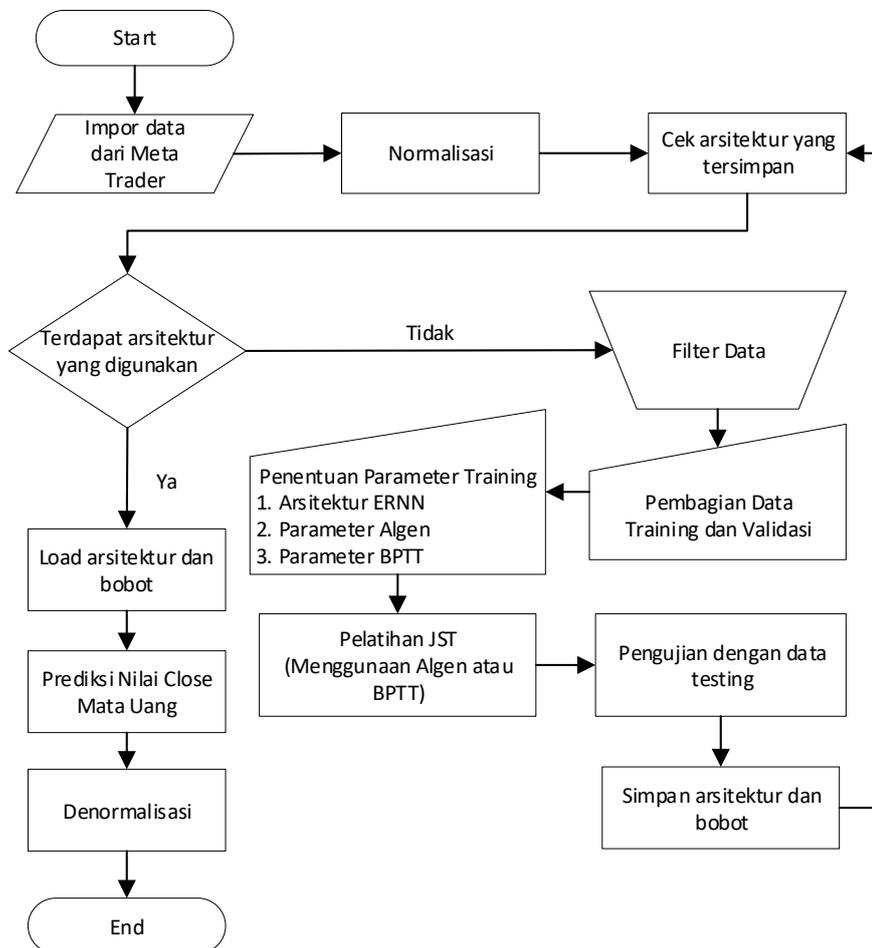
Pada bidang forecasting, Jaringan Syarat Tiruan telah diuji coba pada berbagai kasus salah satunya untuk prediksi nilai tukar mata uang. Perdagangan nilai tukar mata uang terjadi akibat adanya perbedaan supply and demand pada waktu yang sama sehingga terjadi fluktuasi nilai mata uang (Septiawan, 2016). Jaringan Saraf Tiruan bekerja dengan melakukan pembelajaran terhadap data pelatihan dari suatu set data. Dari pelatihan inilah JST akan memperoleh pengetahuan berupa hubungan masukan dan keluaran dalam sistem. Melihat risiko tinggi yang terdapat dalam perdagangan nilai tukar mata uang maka JST dapat dijadikan solusi untuk memberikan prediksi harga tukar. Pada proses peramalan nilai tukar mata uang, diharapkan proses yang cepat sebab tingkat fluktuasi mata uang berjalan cepat. Pendekatan menggunakan JST didukung oleh (Zorin, 2003) dimana pemanfaatan JST dalam prediksi dipandang tepat karena karakteristik JST yang melalui proses training. Terdapat berbagai macam algoritma yang dikembangkan untuk pembelajaran JST dimana diantaranya adalah pembelajaran Backpropagation, namun Backpropagation memiliki kekurangan dalam hal konvergensi error yang lambat dan tidak stabil karena memiliki risiko untuk terjebak dalam lokal minimum.

Algoritma Genetika bermanfaat dalam menghindari stuck pada lokal minimum dan memberikan hasil yang lebih stabil (Ding, 2011). Berdasarkan adanya kelemahan JST maka diusulkan memanfaatkan algoritma optimasi sebagai metode pembelajaran. Algoritma Genetika dipilih karena kemampuannya dalam menemukan optimum global yang berdampak pada kestabilan hasil prediksi (Warsito, 2012). Selain itu kemampuan dalam ruang masalah kompleks, sulit dipahami, tidak terdapat analisis matematika dan kurangnya pengetahuan dalam representasi (Suyanto, 2005) menjadi sangat berperan dalam mempercepat pembelajaran. Pengkombinasian Algoritma Genetika dengan ERNN telah digunakan pada beberapa penelitian tentang peramalan time series yang menghasilkan prediksi yang lebih baik daripada penggunaan metode pembelajaran Backpropagation. Arsitektur ERNN dinilai sesuai digunakan pada permasalahan time

series forecasting dimana karakteristik data time series adalah adanya keterikatan setiap data dari waktu ke waktu sehingga dengan adanya feedback jaringan mampu mempelajari dependensi waktu dari data latih dan memprediksi data yang akan datang (Harsono, 2011).

Pada perkembangannya ERNN sering memanfaatkan metode Backpropagation Through Time. Pada penelitian ini, peningkatan akurasi dan kecepatan pembelajaran akan dibandingkan antara pembelajaran menggunakan Algen dan Backpropagation Through Time yang bertujuan untuk mengetahui seberapa perubahan yang terjadi dengan pengubahan metode pembelajaran. Pemanfaatan Algoritma Genetika untuk optimasi JST telah dilakukan pada beberapa penelitian diantaranya adalah (Ding, 2011), (Torregoza, 2014), (Sespajayadi, 2015) dan (Suhendra, 2015)

2. Metode Penelitian



Gambar 1 Arsitektur jaringan ERNN

2.1 Rancangan Sistem

Alur kerja sistem secara umum diawali dengan pengumpulan data yang didapat dari aplikasi *Meta Trader 4 Admiral Market* yang digunakan sebagai data *training* dan

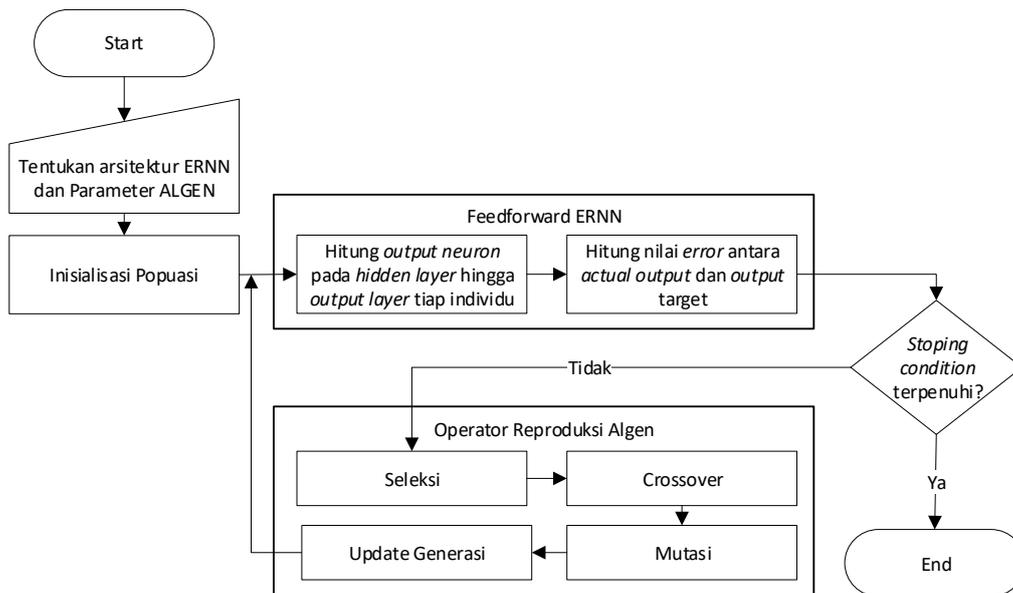
validasi untuk mendapatkan bobot dan arsitektur terbaik dari jaringan. Setelah data didapatkan maka dilakukan proses normalisasi ke rentang [-1:1] menyesuaikan dengan fungsi aktivasi *Hyperbolic Tangen* yang akan digunakan. Adapun alurnya dapat digambarkan seperti Gambar 1.

Pertama dilakukan proses *import* data yang digunakan dan dilakukan proses normalisasi. Setelah proses normalisasi maka dilanjutkan melakukan pengecekan pada arsitektur yang telah dimiliki jika sebelumnya telah melakukan pelatihan. Jika tidak terdapat arsitektur, baik karena arsitektur tidak dirasa cukup baik ataupun belum melakukan training, maka dilanjutkan dengan melakukan proses *training*.

2.2. Rancangan algoritma *hybrid*

Rancangan algoritma *hybrid* akan membahas algoritma genetika sebagai pembelajaran dari ERNN. Gambar 2 menggambarkan secara umum proses yang terjadi.

Setelah penentuan arsitektur dan inialisasi populasi maka tiap individu akan melakukan perhitungan nilai *error* menggunakan *Feedforward ERNN*. Nilai error akan diubah menjadi nilai *fitness* tiap individu. Penentuan bobot baru terbaik dengan memilih individu yang memiliki nilai *fitness* terbesar. Jika kondisi berhenti belum terpenuhi maka individu terpilih akan melakukan proses reproduksi dengan operator reproduksi Algen. Mendapatkan error dengan menggunakan MSE seperti Persamaan 1 (Boden, 2001).



Gambar 2. *Flow Chart* Algoritma *Hybrid* ERNN-ALGEN

Keterangan:

Stopping Condition = $fitness \leq target_error$ atau
 $generasi \geq max_generasi$ atau
konvergen = *True*

Konvergen = *Fitness* tidak berubah selama 50 generasi.

$$MSE = \frac{1}{n} \sum_p^n (d_p - y_p)^2 \quad (1)$$

dimana, n adalah jumlah data pelatihan, d adalah data aktual, dan y adalah output peramalan. Arah gerak ramalan dapat diukur dengan *directional statistics* (Dstat) yang banyak dipergunakan pada masalah peramalan. Adapun persamaan Dstat ditunjukkan pada Persamaan 2 (Sihabuddin, 2016).

$$D_{stat} = \frac{1}{n} \sum_{t=1}^n a_t * 100\% \tag{2}$$

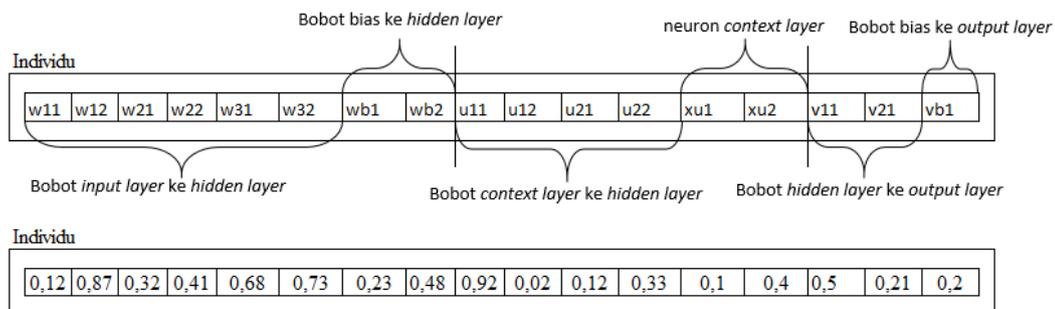
where,

$$a_t = \begin{cases} 1, & (d_{t+1} - d_t)(y_{t+1} - d_t) \geq 0 \\ 0, & otherwise \end{cases} \tag{3}$$

n adalah jumlah data pelatihan, d adalah data aktual, dan y adalah output peramalan

2.3. Rancangan representasi kromosom

Penggunaan Algen dalam optimasi bobot JST menggunakan *real-number encoding* yang diinisialisasi secara *random* dengan rentang nilai [0:1] dimana setiap bobot akan dijadikan gen. Lebih jelasnya maka akan diberikan contoh arsitektur seperti Gambar 3.



Gambar 3. Rancangan representasi kromosom

Keterangan

w_{ij} = Bobot dari *input* i menuju *neuron hidden* ke j .

w_{bj} = Bobot dari bias menuju *neuron hidden* ke j .

u_{ij} = Bobot dari *context unit* i menuju *neuron hidden* ke j .

x_{uj} = Nilai dari *context unit* i .

v_{ij} = Bobot dari *hidden* i menuju *neuron output* ke j .

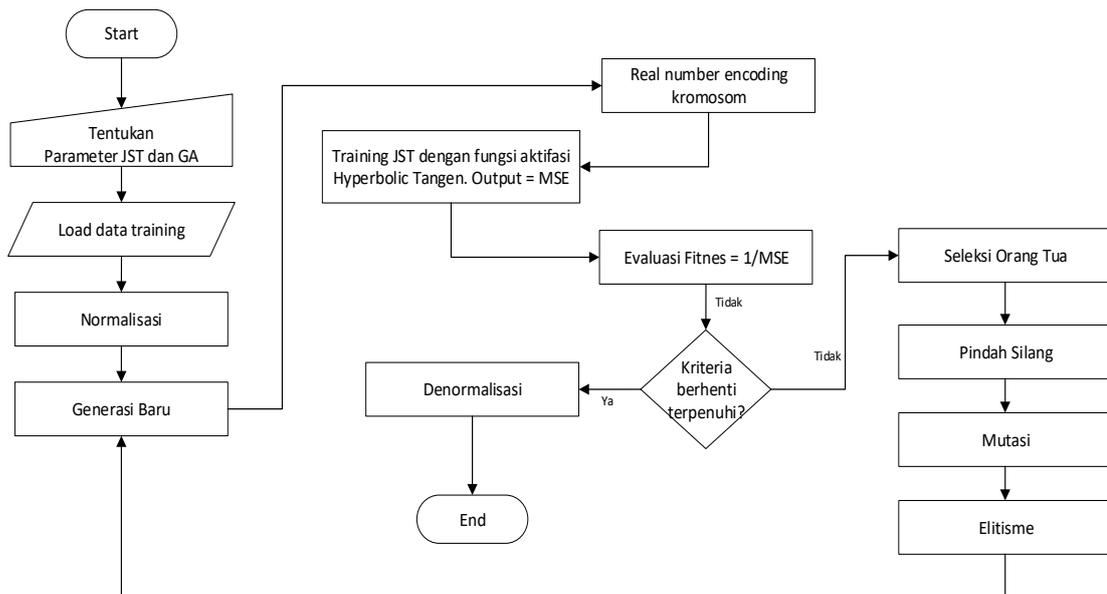
Penggambaran berawal dari bobot pada *input* ke *hidden layer*, dilanjutkan dengan bobot bias kemudian bobot *context layer* dan nilai *context layer*. Selanjutnya bobot pada *hidden* ke *output layer* disusul dengan bobot bias.

2.4. Rancangan Pembelajaran

Berdasarkan beberapa rancangan penelitian yang telah dijabarkan maka untuk memperjelas perancangan akan diberikan rancangan pembelajaran sistem. Pembelajaran akan memanfaatkan data *training* untuk dipelajari pola datanya. Proses ini dilakukan hingga kondisi berhenti tercapai. Rancangan sistem ditunjukkan pada Gambar 4.

Proses diawali dengan penentuan parameter yang diperlukan untuk JST dan Algen. Kemudian dilakukan *load* data *training* dan dilakukan proses normalisasi untuk

memetakan data ke *range* [-1:1]. Fungsi aktivasi yang dipilih adalah *Hyperbolic Tangen*. Setelah data dan parameter siap, Algen membangkitkan generasi baru yang gennya terdiri dari sejumlah bobot dari jaringan. Pembangkitan ini dengan representasi *real* mengikuti representasi kromosom. *Feedforward* JST dilakukan untuk mendapatkan nilai *error* yang diubah menjadi nilai *fitness* tiap individu. Dilakukan pencocokan dengan kondisi berhenti untuk memastikan nilai *error* dapat ditoleransi atau tidak. Jika tidak maka proses berlanjut dengan menggunakan tahapan dari reproduksi Algen untuk menentukan bobot baru. Proses ini berulang hingga *error* yang didapat kurang dari sama dengan target *error* atau sejumlah jumlah *Epoch*.



Gambar 4. Rancangan representasi kromosom

3. Hasil dan Pembahasan

Pada penelitian ini data yang digunakan merupakan data nilai tukar mata uang yaitu USDJPY dan GBPUSD. Data yang digunakan yaitu data *history* nilai tukar harian dari tanggal 1 Januari 2011 hingga 31 Desember 2016. Nilai yang diramalkan berupa nilai *Close* mata uang pada $t+1$. Tiap algoritma pembelajaran akan diuji menggunakan data yang didapatkan. Tahapan pengujian akan diawali dengan pengujian *hyperparameter* dari masing-masing algoritma mulai dari penentuan arsitektur, *learning rate*, ukuran populasi, probabilitas *crossover* dan probabilitas, mutasi. Berdasarkan pengujian *hyperparameter* didapatkan nilai *hyperparameter* seperti pada Tabel 1. Parameter yang didapat akan dipergunakan pada proses pengujian selanjutnya.

Tabel 1. Hasil pengujian hyperparameter

| Mata Uang | Arsitektur | Learning Rate | Ukuran populasi | Probabilitas Crossover | Probabilitas Mutasi |
|-----------|------------|---------------|-----------------|------------------------|---------------------|
| USDJPY | 5-10-1 | 0,025 | 30 | 0,9 | 0,15 |
| GBPUSD | 5-10-1 | 0,025 | 40 | 0,6 | 0,1 |

Pengujian Jumlah Iterasi

Proses pengujian jumlah iterasi bertujuan untuk mengetahui seberapa besar pergerakan tiap algoritma pada tiap iterasi. Hasil dari pengujian iterasi ditampilkan pada Tabel 2 yang merupakan pengurangan dari hasil iterasi dari Algen dikurangi hasil iterasi BPTT.

Tabel 2. Pengurangan hasil iterasi Algen dengan BPTT USDJPY

| No | Rata-rata Epoch/Generasi | Rata-rata <i>Training</i> | | Rata-rata Validasi | | Rata-rata Durasi (detik) |
|----|-----------------------------|---------------------------|---------|--------------------|---------|--------------------------------|
| | | MSE | RMSE | MSE | RMSE | |
| 1 | 1 | 0,1213 | 0,0913 | 0,0264 | 0,0580 | -0.0389 |
| 2 | 2 | 0,2163 | 0,1935 | 0,0246 | 0,0683 | 0.4327 |
| 3 | 5 | -0,1535 | -0,1645 | 0,1974 | 0,3131 | 1.8397 |
| 4 | 10 | -0,2422 | -0,4009 | 0,0257 | 0,0225 | 4.1841 |
| 5 | 15 | -0,2308 | -0,4018 | 0,0022 | -0,0013 | 6.5196 |
| 6 | 30 | -0,1317 | -0,3157 | -0,0117 | -0,0665 | 13.5529 |
| 7 | 50 | -0,2080 | -0,4113 | -0,0038 | -0,0301 | 22.8918 |
| 8 | 75 | -0,0969 | -0,2602 | -0,0053 | -0,0389 | 34.6846 |
| 9 | 100 | -0,0916 | -0,2559 | -0,0178 | -0,0708 | 46.2955 |
| 10 | 500 | -0,0028 | -0,0341 | 0,0037 | 0,0253 | 233.0594 |
| 11 | 1000 | -0,0027 | -0,0370 | 0,0018 | 0,0191 | 466.3975 |
| 12 | 2000 | -0,0037 | -0,0462 | -0,0011 | -0,0080 | 931.5991 |
| 13 | 4000 | -0,0023 | -0,0363 | -0,0026 | -0,0266 | 1865.4750 |
| 14 | 5000 | -0,0016 | -0,0244 | -0,0012 | -0,0103 | 2328.2231 |

Keterangan: - Angka yang ditebalkan = BPTT lebih kecil dari Algen

Berdasarkan Tabel 2 terlihat jika dilakukan 2 iterasi, BPTT memiliki rata-rata proses yang lebih cepat. Pada iterasi maksimal 15, BPTT memiliki *error* lebih kecil dari algen pada data validasi. Lebih dari 15 iterasi, algen memiliki *error* lebih kecil dari BPTT. Hal ini berasal dari kemampuan Algen untuk mencari solusi pada ruang pencarian sehingga dapat *error* dapat jauh mengecil. Pada iterasi 500 dan 1000, BPTT kembali memiliki *error* lebih kecil dari Algen pada data validasi. Hal ini disebabkan algen tidak kunjung mendapatkan individu terbaik yang baru Terlihat *error* Algen rata-rata lebih rendah dari BPTT namun dengan waktu yang lebih lama. Setelah melakukan percobaan pada USDJPY, akan dilakukan juga percobaan yang serupa dengan GBPUSD. Adapun hasil pengujian iterasi pada GBPUSD adalah sebagai berikut.

Tabel 3. Pengurangan hasil iterasi Algen dengan BPTT GBPUSD

| No. | Rata-rata <i>Epoch/Generasi</i> | Rata-rata <i>Training</i> | | Rata-rata Validasi | | Rata-rata Durasi (detik) |
|-----|------------------------------------|---------------------------|----------|--------------------|----------|--------------------------------|
| | | MSE | RMSE | MSE | RMSE | |
| 1 | 1 | 0.143374 | 0.204108 | 0.361919 | 0.185146 | -0.03653 |
| 2 | 2 | 0.133179 | 0.185298 | 0.446425 | 0.265623 | 0.500726 |
| 3 | 5 | -0.00532 | 0.01631 | -0.32274 | -0.28259 | 2.130131 |
| 4 | 10 | -0.05797 | -0.15211 | -0.02412 | -0.01248 | 4.858018 |
| 5 | 15 | -0.02337 | -0.09951 | -0.0916 | -0.13327 | 7.474978 |
| 6 | 30 | -0.02471 | -0.10925 | 0.088313 | 0.106011 | 15.45092 |
| 7 | 50 | -0.01364 | -0.06176 | -0.08821 | -0.12151 | 26.20027 |
| 8 | 75 | -0.01255 | -0.06679 | 0.388167 | 0.312042 | 40.18628 |
| 9 | 100 | -0.02282 | -0.11552 | -0.17846 | -0.26486 | 52.64636 |
| 10 | 500 | -0.01709 | -0.09115 | 0.081368 | 0.097543 | 266.2312 |
| 11 | 1000 | -0.01235 | -0.06322 | -0.16858 | -0.06128 | 531.5083 |
| 12 | 2000 | -0.00626 | -0.04724 | 0.02539 | 0.013543 | 1055.811 |
| 13 | 4000 | -0.00258 | -0.02686 | 0.30195 | 0.207968 | 2090.881 |
| 14 | 5000 | -0.00123 | -0.01472 | 0.194332 | 0.197926 | 2611.983 |

Keterangan: - Angka yang ditebalkan = BPTT lebih kecil dari Algen

Berdasarkan Tabel 3 terlihat jika BPTT memiliki *error* yang lebih kecil pada mayoritas iterasi pada data validasinya. Namun Algen mampu lebih baik pada mayoritas data *training*. Hal ini dikarenakan kemampuan algen dalam mencari bobot dengan P_m 0,1 cenderung kurang variatif sehingga individu monoton dan jarang terjadi perubahan pada individu terbaiknya. Dari percobaan ini terlihat *error* Algen rata-rata lebih rendah dari BPTT pada data *training* dan BPTT memiliki rata-rata *error* lebih kecil pada data validasi. Dari sisi waktu, BPTT rata-rata lebih cepat dibandingkan dengan Algen.

Pengujian Alokasi Waktu

Proses pengujian alokasi waktu bertujuan untuk mengetahui seberapa besar pergerakan tiap algoritma pada tiap waktu. Hasil dari pengujian iterasi ditampilkan pada Tabel 4 yang merupakan pengurangan dari hasil iterasi dari Algen dikurangi hasil iterasi BPTT.

Tabel 4. Pengurangan akurasi pengujian waktu Algen dengan BPTT pada USDJPY

| No. | Menit | Rata-rata <i>Epoch/Generasi</i> | Rata-rata <i>Training</i> | | Rata-rata Validasi | | Rata-rata Durasi (detik) |
|-----|-------|------------------------------------|---------------------------|---------|--------------------|---------|--------------------------------|
| | | | MSE | RMSE | MSE | RMSE | |
| 1 | 0,5 | -751,3 | -0,0077 | -0,0612 | -0,0005 | -0,0056 | 0.176024 |
| 2 | 1 | -1504,7 | -0,0081 | -0,0540 | 0,0111 | 0,0448 | 0.162535 |
| 3 | 2 | -3008,0 | -0,0053 | -0,0489 | 0,0047 | 0,0239 | 0.214302 |
| 4 | 3 | -4512,7 | -0,0061 | -0,0539 | 0,0031 | 0,0146 | 0.272267 |
| 5 | 5 | -7513,3 | -0,0019 | -0,0251 | 0,0133 | 0,0696 | 0.346493 |
| 6 | 7 | -10543,0 | -0,0213 | -0,1095 | -0,0037 | -0,0219 | 0.411164 |
| 7 | 10 | -15047,0 | -0,0044 | -0,0532 | -0,0018 | -0,0197 | 0.160307 |
| 8 | 15 | -22559,0 | -0,0079 | -0,0628 | -0,0026 | -0,0183 | 0.045324 |
| 9 | 20 | -30099,7 | -0,0011 | -0,0205 | -0,0009 | -0,0103 | 0.363244 |

Berdasarkan Tabel 4 terlihat jika Algen memerlukan waktu lebih banyak pada setiap iterasinya karena banyaknya proses yang dilakukan setiap iterasi algen. Jika

dilihat berdasarkan waktu, BPTT mampu melakukan iterasi lebih banyak namun *error* yang didapatkan rata-rata lebih besar kecuali pada alokasi waktu 1, 2, 3, dan 5 menit pada data validasi. Terlihat pula penurunan selisih *error* jika semakin lama. Hal ini terjadi karena proses diversifikasi Algen berjalan cukup lama dan sulit menemukan individu baru yang terbaik dengan kondisi banyak individu dengan gen yang serupa. Setelah pengujian waktu pada USDJPY selanjutnya akan dilakukan pengujian pada GBPUSD. Adapun hasil pengujiannya akan adalah sebagai berikut.

Berdasarkan Tabel 5 terlihat jika Algen memerlukan waktu lebih banyak pada setiap iterasinya. Jika dilihat berdasarkan jumlah iterasi, BPTT mampu melakukan iterasi lebih banyak pada satuan waktu tertentu namun *error* yang didapatkan rata-rata lebih besar dibandingkan Algen kecuali pada alokasi waktu 1, 2, 5, dan 8 menit pada data validasi. Pada percobaan kali ini algen memiliki kesulitan dalam menemukan individu baru sebagai variasi individu sehingga individu baru tidak kunjung berubah

Tabel 5. Pengurangan akurasi pengujian waktu Algen dengan BPTT pada GBPUSD

| No. | Menit | Rata-rata <i>Epoch/Generasi</i> | Rata-rata <i>Training</i> | | Rata-rata Validasi | | Rata-rata Durasi (detik) |
|-----|-------|------------------------------------|---------------------------|---------|--------------------|---------|--------------------------------|
| | | | MSE | RMSE | MSE | RMSE | |
| 1 | 30 | -698.0 | -0.0024 | -0.0078 | 0.5220 | 0.6107 | 0.2023 |
| 2 | 60 | -1398.3 | 0.0015 | 0.0170 | 0.1546 | 0.1132 | 0.0804 |
| 3 | 120 | -2895.7 | -0.0060 | -0.0411 | -0.1571 | -0.1471 | 0.1858 |
| 4 | 180 | -4458.7 | -0.0082 | -0.0591 | -0.0243 | -0.0376 | 0.1059 |
| 5 | 300 | -7396.3 | -0.0037 | -0.0309 | 0.3088 | 0.3030 | 0.4063 |
| 6 | 420 | -10411.0 | -0.0092 | -0.0667 | -0.1505 | -0.2183 | 0.2591 |
| 7 | 600 | -14958.0 | -0.0078 | -0.0503 | -0.2252 | -0.2516 | -59.5587 |
| 8 | 900 | -22171.0 | -0.0035 | -0.0309 | 0.1495 | 0.0626 | -99.6557 |
| 9 | 1200 | -29063.7 | -0.0119 | -0.0767 | -0.0251 | -0.0314 | -99.6242 |

Keterangan: - Angka yang ditebalkan: BPTT lebih kecil dari Algen

Analisis Pembelajaran

Parameter waktu pelatihan digunakan untuk membandingkan kecepatan waktu pelatihan. Pengukuran dilakukan berdasarkan waktu dan akurasi pembelajaran dari masing-masing metode pembelajaran.

Tabel 6. Pengujian akurasi pelatihan GBPUSD

| No. | Algoritma | Generasi/ <i>Epoch</i> | <i>Training</i> | | Validasi | | Durasi |
|-----|-----------|------------------------|-----------------|--------|----------|--------|----------|
| | | | MSE | Dstat | MSE | Dstat | |
| 1 | Algen | 9439 | 0.0007 | 59.522 | 0.0052 | 56.889 | 4959.13 |
| 2 | Algen | 539 | 0.0014 | 55.049 | 0.3659 | 53.441 | 310.28 |
| 3 | BPTT | 1000000 | 0.0097 | 52.813 | 0.0383 | 55.315 | 36459.70 |
| 4 | BPTT | 1000000 | 0.0153 | 53.317 | 0.7151 | 52.165 | 35974.92 |

Keterangan: -Tulisan yang ditebalkan = arsitektur dan bobot yang digunakan.

Tabel 6 menunjukkan bahwa Algen mampu memberikan MSE lebih kecil dari BPTT baik dari data *training* atau data validasinya. Selain MSE yang lebih kecil, waktu yang dibutuhkan juga lebih kecil. Hal ini terjadi karena kondisi berhenti Algen adalah konvergen sedangkan BPTT berhenti dengan kondisi jumlah *epoch* sehingga kedua

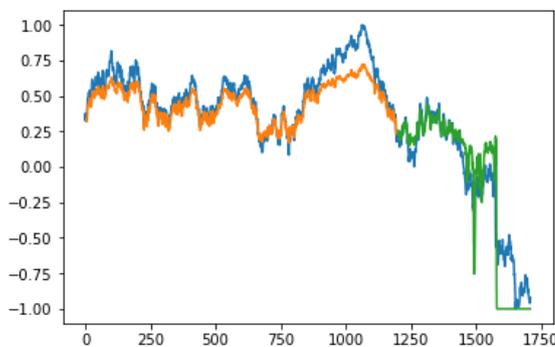
algoritma tersebut tidak mencapai target *error* yang diinginkan. Dilihat dari Dstat, kedua algoritma juga belum dapat diterapkan pada industri karena Dstat belum mampu melampaui 60%.

Tabel 7. Pengujian akurasi pelatihan USDJPY

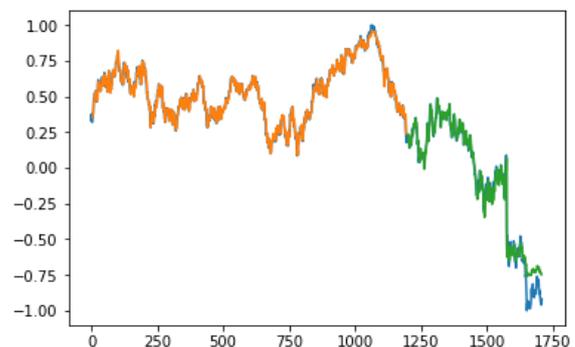
| No. | Algoritma | Generasi/Epoch | Training | | Validasi | | Durasi |
|-----|-----------|----------------|----------|--------|----------|--------|----------|
| | | | MSE | Dstat | MSE | Dstat | |
| 1 | Algen | 1133 | 0.0006 | 60.042 | 0.0020 | 56.606 | 742.27 |
| 2 | Algen | 179 | 0.0013 | 56.561 | 0.0197 | 53.787 | 117.13 |
| 3 | BPTT | 1000000 | 0.0536 | 53.736 | 0.0383 | 51.575 | 36371.46 |
| 4 | BPTT | 1000000 | 0.0012 | 54.156 | 0.0024 | 54.134 | 36607.81 |

Keterangan: -Tulisan yang ditebalkan = arsitektur dan bobot yang digunakan.

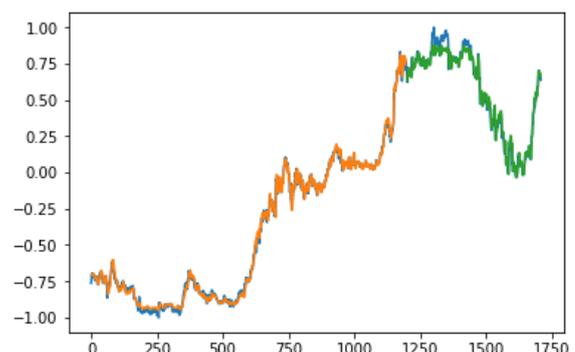
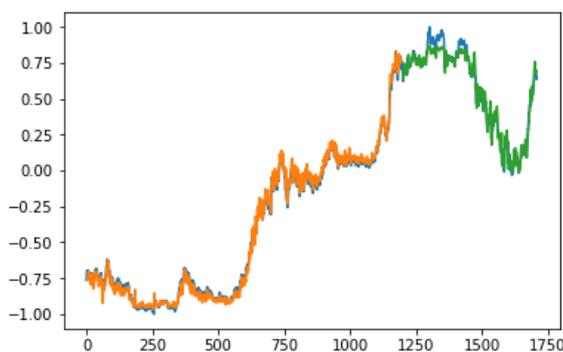
Tabel 7 menunjukkan bahwa Algen mampu memberikan MSE lebih kecil pada data *training* dan validasi sekaligus serta waktu pelatihan yang lebih kecil dari BPTT. Secara iterasi, algen memerlukan waktu lebih lama tiap iterasinya namun memerlukan sedikit iterasi sehingga algen mampu lebih cepat. Kecepatan ini dikarenakan kondisi berhenti Algen adalah konvergen sedangkan BPTT berhenti dengan kondisi jumlah *epoch*. Kedua Algoritma tersebut tidak mencapai target *error* yang diinginkan. Dilihat dari Dstat, kedua algoritma belum mampu diterapkan pada industri karena belum mencapai Dstat 60%. Hal menarik ditemukan dimana arsitektur yang memiliki *error* yang lebih besar mampu memberikan Dstat yang sama atau lebih baik. Hal ini dikarenakan sifat dstat yang mengukur kesamaan arah antara peramalan dan aktualnya. Jika arah tidak sesuai maka diberikan nilai 0 sekalipun dengan prediksi yang dekat dengan aktual sehingga arsitektur yang MSE kecil dapat menghasilkan Dstat yang kurang baik. Peramalan yang dilakukan akan disajikan berupa grafik yang ditunjukkan oleh Gambar 5, Gambar 6, Gambar 7 dan Gambar 8



Gambar 5. Plot peramalan GBPUSD dengan BPTT



Gambar 6. Plot peramalan GBPUSD dengan Algen



Gambar 7. Plot peramalan USDJPY dengan BPTT

Gambar 8. Plot peramalan USDJPY dengan AI

Keterangan:

Warna biru = data set

Warna oranye = hasil peramalan data *training*

Warna hijau = hasil peramalan data validasi

Setelah mendapatkan arsitektur maka dilakukan pengujian dengan menggunakan data uji. Data uji yang digunakan adalah data tanggal 3-7 April 2018 untuk meramalkan tanggal 9 April 2018. Hasilnya ditunjukkan Tabel 8 dan Tabel 9.

Tabel 8. Pengurangan akurasi pengujian USD-JPY

| No. | Hari | Aktual | Ramalan Algen | Ramalan BPTT | Selisih Algen | Selisih BPTT |
|-----|-----------|---------|------------------|-----------------|---------------|-----------------|
| 1 | 2 | 3 | 4 | 5 | 6 = 3-4 | 7 = 3-5 |
| 1 | 9/4/2018 | 106.745 | 107.487 (S) | 107.528 (S) | 0.7425 | 0.7828 |
| 2 | 10/4/2018 | 107.197 | 107.368 (B) | 107.009 (B) | 0.1710 | 0.1883 |
| 3 | 11/4/2018 | 106.785 | 107.539 (S) | 107.437 (S) | 0.7537 | 0.6521 |
| 4 | 12/4/2018 | 107.301 | 107.091 (B) | 107.126 (B) | 0.2098 | 0.1745 |
| 5 | 13/4/2018 | 107.372 | 107.620 (B) | 107.713 (B) | 0.2477 | 0.3411 |

Keterangan:

Dicetak tebal = selisih yang lebih mendekati nilai aktual

(B) = Arah peramalan sesuai dengan arah nilai aktual

(S) = Arah peramalan tidak sesuai dengan arah nilai aktual

Arah peramalan diambil dari penentuan α_t Dstat pada Persamaan 3.13. Jika $\alpha_t = 1$ maka (B) jika tidak maka (S). Berdasarkan Tabel 8 terlihat peramalan Algen memiliki selisih yang lebih kecil pada tiga tanggal dan lebih buruk pada dua tanggal. Hasil ini memberi gambaran bahwa Algen mampu memberikan hasil ramalan lebih dekat pada beberapa tanggal dengan nilai aktual pada USDJPY.

Tabel 9. Pengurangan akurasi pengujian GBP-USD

| No. | Hari | Aktual | Ramalan Algen | Ramalan | Selisih Algen | Selisih BPTT |
|-----|-----------|---------|------------------|--------------|---------------|-----------------|
| 1 | 2 | 3 | 4 | 5 | 6 = 3-4 | 7 = 3-5 |
| 1 | 9/4/2018 | 1.41293 | 1.39647 (B) | 1.379654 (B) | 0.0165 | 0.0333 |
| 2 | 10/4/2018 | 1.41739 | 1.40630 (B) | 1.362431 (B) | 0.0111 | 0.0550 |
| 3 | 11/4/2018 | 1.41746 | 1.40533 (B) | 1.375095 (B) | 0.0121 | 0.0424 |
| 4 | 12/4/2018 | 1.42276 | 1.40908 (B) | 1.381508 (B) | 0.0137 | 0.0413 |
| 5 | 13/4/2018 | 1.42382 | 1.41308 (B) | 1.41921 (B) | 0.0107 | 0.0046 |

Keterangan:

Dicetak tebal = selisih yang lebih mendekati nilai aktual

(B) = Arah peramalan sesuai dengan arah nilai aktual

(S) = Arah peramalan tidak sesuai dengan arah nilai aktual

Seperti halnya percobaan pada USDJPY, pada percobaan GBPUSD juga menggunakan arah peramalan yang persamaannya diambil dari penentuan α_t Dstat pada Persamaan 3.13 dimana jika $\alpha_t = 1$ maka (B) jika tidak maka (S). Berdasarkan Tabel 6.57 terlihat peramalan Algen memiliki selisih yang lebih kecil pada empat tanggal yang diujikan. Hasil ini mempertegas bahwa akurasi dengan pembelajaran Algen memiliki hasil ramalan lebih dekat dengan nilai aktual dibandingkan dengan BPTT pada GBPUSD.

4. Kesimpulan

Algoritma Genetika sebagai alternatif metode pembelajaran JST mampu memberikan nilai *error* yang kecil dengan hasil prediksi yang lebih dekat dengan nilai aktual dibandingkan BPTT. Selain itu dari sisi kecepatan pembelajaran Algen juga mampu lebih cepat dibandingkan BPTT karena pada Algen memerlukan generasi yang sedikit walaupun pada tiap generasi memerlukan waktu yang panjang. Kedua algoritma tidak dapat mencapai target *error* yang ditentukan yang berefek pada Dstat dari kedua algoritma belum mampu mencapai 60% sehingga belum dapat diterapkan pada industri.

Skema penggabungan ERNN dengan Algen dimana hanya digunakan fase *feedforward* untuk mengukur besarnya *fitness* dan selebihnya dilakukan Algen. Skema ini mampu menjadi alternatif pembelajaran ERNN dan penggabungannya dapat menggunakan algoritma evolusi lain pada pembelajaran JST.

5. Saran

Kemampuan Algen konvergen pada target 0,0001 dengan iterasi yang lebih sedikit memberi peluang untuk algoritma evolusi lain dapat diterapkan pada pembelajaran JST. Algoritma evolusi yang dapat dipilih berdasarkan kecepatan tiap iterasi lebih cepat dari Algen. Pemilihan arsitektur dapat mencoba menggunakan MLP agar meminimalisir jumlah gen yang *dirandom* (tanpa *context layer*) dengan harapan memperkecil ruang pencarian Algen. Monotonnya individu memberikan efek pada kecepatan konvergensi, dapat dicoba dengan peningkatan jumlah Pm atau dengan penambahan individu baru pada beberapa kali iterasi untuk mempertahankan keragaman individu pada populasi.

Daftar Pustaka

- Boden, M. (2001) 'A guide to recurrent neural networks and backpropagation', *Electrical Engineering*, (2), pp. 1–10. doi: 10.1.1.16.6652.
- Ding, S., Su, C. and Yu, J. (2011) 'An optimizing BP neural network algorithm based on genetic algorithm', *Artificial Intelligence Review*, 36(2), pp. 153–162. doi: 10.1007/s10462-011-9208-z.

- Harsono, I. T., Wibowo, A. T. and Dayawati, R. N. (2011) 'Analisis dan Implementasi Elman Recurrent Neural Network dan Tabu Search Pada Prediksi Harga Perak', pp. 0–6.
- Salman, A. G. (2011) 'Implementasi Jaringan Saraf Tiruan Recurrent dengan Metode Pembelajaran Gradient Descent Adaptive Learning Rate untuk Pendugaan Curah Hujan', 2011(Snati), pp. 17–18.
- Septiawan, F. Y. and Afiahayati (2016) *Prediksi Nilai Tukar Mata Uang dalam Sistem Forex Trading Menggunakan Algoritma Genetika*. Universitas Gadjah Mada.
- Sespajayadi, A., Indrabayu and Nurtanio, I. (2015) 'Technical Data Analysis for Movement Prediction of Euro to USD Using Genetic Algorithm-Neural Network', pp. 23–26.
- Sihabuddin, A. and Hartati, S. (2016) 'Exchange Rates', in. AIP Publishing. Available at: <http://www.exchangerates.org.uk/USD-KES-exchange-rate-history-full.html>.
- Suyanto (2005) *Algoritma Genetika dalam Matlab*. Yogyakarta: Andi.
- Suhendra, C. D. and Wardoyo, R. (2015) 'Penentuan Arsitektur Jaringan Saraf Tiruan Backpropagation (Bobot Awal dan Bias Awal) Menggunakan Algoritma Genetika', 9(1), pp. 77–88.
- Torregoza, M. L. R. and Dadios, E. P. (2014) 'Comparison of Neural Network and Hybrid Genetic Algorithm-Neural Network in Forecasting of Philippine Peso-US Dollar Exchange Rate', (November).
- Warsito, B. *et al.* (2012) 'Penentuan Bobot Model Neural Network Untuk Data Time Series', *Konferensi Nasional Matematika XVI*.
- Zorin, A. (2003) 'Stock price prediction: Kohonen versus backpropagation', *Ann*, pp. 3–7.