

ANALISIS METODE RBF-NN DAN GRNN PADA PERAMALAN MATA UANG EUR/USD

Ayuni Harianti¹, Nengah Widiangga²

¹ Program studi sistem informasi ISTNUBA,

² Program Studi Manajemen logistik Politeknik Transportasi Darat Bali

E-mail : ayuniharianti@gmail.com

Abstrak – Penelitian ini merupakan lanjutan dari penelitian sebelumnya tentang peramalan EUR/USD menggunakan metode RBF-NN (*Radial Basis Function – Neural Network*) yang dioptimasi dengan Algoritma Genetika. Metode yang ditambahkan adalah GRNN (*Generalized Regression Neural Network*). Sistem RBF-NN dapat diterapkan pada data dengan karakteristik nonlinear dan fluktuatif seperti data EUR/USD, sementara GRNN dapat bekerja dengan baik jika data training tersedia dalam jumlah banyak. Tingkat keakuratan dari peramalan ditunjukkan lewat nilai MAPE (*Mean Absolut Percentage Error*).

Dari hasil percobaan, metode GRNN tidak memiliki nilai MAPE yang lebih baik daripada RBF-NN baik pada data *daily low* maupun data *daily high*. Teknik pencarian algoritma genetika di dekat bobot RBF-NN terbukti lebih efektif daripada pendekatan fungsi GRNN dengan *spread* kecil pada kasus mata uang EUR/USD.

Kata Kunci : EUR/USD; RBF-NN; Algoritma Genetika; GRNN; MAPE; *spread*; *daily high*; *daily low*.

Abstract – This research is the continuation of previous paper regarding EUR/USD forex forecasting using RBF-NN (*Radial Basis Function – Neural Network*) method optimized by Genetic Algorithm (GA). The additional method is GRNN (*Generalized Regression Neural Network*). RBF-NN can be applied to nonlinear and fluctuative data like EUR/USD, while GRNN works well if great number of training data is available. The accuracy level of forecasting is shown by MAPE (*Mean Absolut Percentage Error*) value.

The result shows that GRNN doesn't have better MAPE value than RBF-NN both on the *daily low* and *daily high* data. GA uses certain technique which searches around RBF-NN's weight, and this technique was proved to be more effective in EUR/USD case than GRNN with small *spread*.

Keywords : EUR/USD; RBF-NN; Algoritma Genetika; GRNN; MAPE; *spread*; *daily high*; *daily low*.

PENDAHULUAN

Forex adalah pasar tempat transaksi mata uang yang beraktivitas nonstop, selama 7 hari seminggu, 24 jam per hari. Komoditas Forex beraneka ragam, dimana salah satunya yaitu mata uang Euro (EUR) dan US Dollar (USD).

Nilai perbandingan atau lazim disebut kurs, dari kedua mata uang ini dikenal dengan istilah EUR/USD, sementara *Trader* adalah istilah yang lazim dipakai kepada orang yang melakukan jual-beli di Forex dengan tujuan mendapatkan keuntungan. Dalam satu kurun waktu tertentu, data Forex memiliki empat nilai yaitu *Open*, *Close*, *Maximum* dan *Minimum*. Nilai ini berlaku pada *time frame* yang berbeda-beda, baik itu data harian, mingguan, bulanan, setiap 1 jam, dll.

Data pada Forex memiliki kemiripan dengan *financial time series* yang cenderung bersifat

nonlinear dan fluktuatif. Yang disebut dengan peramalan data Forex adalah proses memperkirakan nilai kurs mata uang tersebut di waktu yang akan datang. *Trader* menggunakan nilai ini untuk memilih apa yang harus dilakukan; melakukan pembelian, penjualan atau tidak bertransaksi. Pola pergerakan data yang rumit menyebabkan peramalan dengan perhitungan manual menemui banyak kesulitan [1].

Pemilihan EUR/USD didasarkan pada pertimbangan bahwa dua mata uang ini mencerminkan kekuatan ekonomi terbesar di dunia saat ini [2]. Hal ini menyebabkan EUR/USD cenderung bersifat likuid dan memiliki kemungkinan yang besar untuk memberikan keuntungan finansial.

Telah banyak penelitian yang mencoba meramalkan data Forex dengan metode seperti

Statistik, Fuzzy Logic, Neural Network [3], [4]. Permasalahan klasik pada peramalan data Forex adalah tingkat akurasi yang kurang karena berhadapan dengan data yang bersifat nonlinear dan fluktuatif.

RBF-NN (*Radial Basis Function – Neural Network*) adalah salah satu model jaringan syaraf tiruan yang dapat digunakan dalam peramalan. Prinsip RBF-NN yaitu mengubah input menggunakan fungsi Gaussian lalu perhitungan dilanjutkan dengan linear [5]. Fungsi *Gaussian* yang menjadi inti dari RBF-NN sejatinya adalah fungsi nonlinear sehingga dapat diterapkan untuk data Forex. Dalam hal sistem RBF-NN yang dilengkapi dengan LMS (*Least Mean Square*), solusi lokal akan membatasi akurasi yang diinginkan.

Salah satu cara mengatasi solusi lokal adalah dengan menggunakan teknik Algoritma Genetika (AG) atau variasinya yaitu Algoritma Genetika Adaptif (AGA). Kedua teknik ini memiliki prinsip kerja yaitu mencari bobot terbaik dari beberapa bobot yang dihasilkan RBF-NN [6]. Model AG dan AGA disusun berdasarkan jenis seleksi, *crossover* (perkawinan) dan mutasi, dimana model AG dan AGA ini bergantung pada nilai probabilitas. Penelitian sebelumnya [7] meneliti metode RBF-NN yang dioptimasi dengan 1 model AG dan AGA, sementara [8] meneliti RBF-NN dengan 3 model AG dan AGA.

GRNN (*generalized regression neural networks*) merupakan salah satu varian dari *radial basis networks* dan sering digunakan pada pendekatan fungsi (*function approximation*). GRNN terdiri atas *radial basis layer* dan *special linear layer*, merupakan algoritma pembelajaran yang didesain bersifat *one-pass learning* dilengkapi dengan struktur paralel. Metode GRNN dapat digunakan untuk prediksi, pemodelan, pemetaan dan interpolasi [9].

Penelitian ini membahas tentang perbandingan antara metode RBF-NN tanpa optimasi, RBF-NN yang dioptimasi dengan AG dan AGA (tipe II) [8], dan GRNN. Nilai yang dibandingkan adalah nilai *error* yang berbentuk MAPE (*Mean Absolute Percentage Error*), dimana semakin kecil MAPE-nya, metode tersebut semakin baik.

Pada model 2 - 5 *cluster*, ada 4 buah nilai MAPE yang akan dianalisis yaitu nilai MAPE dari metode RBF-NN tanpa optimasi, RBF-NN dengan AG (tipe II), RBF-NN dengan AGA (tipe II) dan GRNN.

TINJAUAN PUSTAKA

A. K-Means Cluster dan RBF-NN

Metode *K-Means Cluster* terlebih dahulu membagi seluruh data menjadi satu atau lebih *cluster* berdasarkan karakteristik. Jadi dalam satu *cluster* akan ditemukan beberapa data yang karakteristiknya mirip, sesuai dengan ketentuan yang dipersyaratkan. Dengan pengelompokan ini, maka *objective function* akan diminimalkan, variasi dalam *cluster* akan minimal sementara variasi antar *cluster* akan bernilai maksimal.

K-Means Cluster mulai dengan memilih nilai K secara acak, dimana nilai K adalah jumlah *cluster* yang ingin dibentuk. Nilai K yang dipilih pertama otomatis menjadi pusat dari *cluster* (*centroid*). Langkah berikutnya adalah menghitung jarak *Euclidian* untuk setiap data terhadap masing-masing *centroid* hingga didapatkan jarak paling kecil. Berdasarkan jarak tersebut, metode ini mengelompokkan setiap data, dan langkah tersebut dilakukan secara repetitif hingga didapatkan nilai *centroid* yang sudah stabil.

RBF-NN (ϕ) merupakan fungsi dengan keluaran yang simetris terhadap *center* (c) atau ditulis $\phi = \phi \|x - c\|$, dengan $\| \cdot \|$ merupakan vektor normal. Berbagai fungsi dapat digunakan namun yang umum digunakan adalah *Gaussian*. Struktur utama RBF-NN adalah tiga *layer* yaitu *layer input*, *hidden layer* dan *layer output*, seperti digambarkan pada Gambar 1.


Langkah berikutnya adalah menentukan *centre*, jumlah *neuron*, matrik ϕ dan matrik t [10]. Nilai untuk σ dalam matrik

$\left[\exp \left(-\frac{\|data - center\|^2}{2\sigma^2} \right) \right]$ diambil dari konstanta yang menggambarkan jarak radial data terhadap *centre*. Persamaan linearnya akan menjadi (1).

$$\phi w = t \quad (1)$$

Lalu bobot (w) dihitung dengan dengan pendekatan *least-square* (2).

$$w = (\phi^T \phi)^{-1} \phi^T t \quad (2)$$



Gambar 1 : Struktur RBF-NN [7]

Hidden layer ditentukan berdasarkan *centre masing-masing cluster*. Data yang masuk ke input layer, diolah pada hidden layer lalu dikalikan dengan bobot sesuai (1). Hasil perkalian ini menggambarkan hasil peramalan oleh RBF-NN.

B. Algoritma Genetika, MAPE, GRNN

Optimasi dapat diartikan sebagai pencarian hasil yang terbaik dari apapun kegiatan kita [11]. Algoritma Genetika adalah suatu teknik optimasi dan pencarian berdasarkan prinsip yang mirip dengan cara kerja alam. Langkah-langkah dalam metode ini meliputi : Representasi dan Inisialisasi Kromosom, Evaluasi *Fitness*, Seleksi, *Crossover* (perkawinan), Mutasi; sementara untuk AGA ditambahkan dengan pemutakhiran nilai probabilitas untuk *crossover* dan mutasi.

Ketentuan umum yang diterapkan pada AG dan AGA (tipe II) adalah sebagai berikut.

- Menggunakan azas elitisme.
- Crossover* ditentukan sebesar 70% (peluang *crossover* pada AGA).
- Mutasi ditentukan sebesar 40% (peluang mutasi pada AGA).
- Populasi dibatas sejumlah 100.

Model algoritma genetika dibentuk dari gabungan beberapa metode. Langkah pertama adalah mengisi nilai kromosom dengan bobot, lalu di-ranking berdasarkan nilai MAPE. Lalu *crossover* menggunakan metode *roulette wheel*; pada saat ini bobot yang ranking-nya lebih rendah cenderung tersingkir oleh bobot dengan ranking lebih tinggi. Pada AGA, kromosom menjalani *crossover* jika nilai *update fitness*-nya lebih besar daripada probabilitas *crossover* yang telah ditetapkan. Mutasi berlaku untuk seluruh

kromosom, melalui pengalihan dengan bilangan random, bobot minimum dan bobot maksimum. Khusus AGA, mutasi baru akan terjadi jika nilai *update fitness* memenuhi probabilitas mutasi. AG dan AGA tipe II berakhir setelah 50 *epoch*, dan MAPE seluruh kromosom akan dihitung.

Algoritma Genetika Adaptif memiliki tambahan penentuan probabilitas *crossover* dan probabilitas mutasi berdasarkan *fitness*. Untuk perhitungan pemutakhiran nilai menggunakan (3) dan (4).

$$p_c = k_1 (f_{max} - f') (f_{max} - \hat{f}) \quad (3)$$

$$p_m = k_2 (f_{max} - f') (f_{max} - \hat{f}) \quad (4)$$

dimana

$$k_1, k_2, k_3 \leq 1.0$$

Keterangan :

p_c adalah probabilitas *crossover*

p_m adalah probabilitas mutasi

f_{max} adalah *fitness* maksimal

f adalah *fitness* terbesar yang ikut bermutasi

f' adalah *fitness* terbesar yang ikut *crossover*

$\hat{f}$ adalah rata-rata *fitness*

Nilai $p_m = 0,6$, $p_c = 0,3$, $k_1 = 0,7$ dan $k_2 = 0,3$.

Dengan penetapan ini proses algoritma genetika diharapkan memberikan jalan *crossover* untuk kromosom dengan *fitness* unggul dan cenderung memutasikan kromosom dengan *fitness* jelek [7]. MAPE dapat dipandang sebagai penilaian kinerja dengan menyatakan selisih antara data prediksi dengan data aktual (dalam bilangan riil), dinyatakan dengan persentase dan mengabaikan penanda positif maupun negatif pada galat [12]. Perumusan MAPE dinyatakan dalam (5).

$$MAPE = \left(\frac{100}{n} \right) \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (5)$$

GRNN adalah suatu *network* yang menghitung *probability density function* (PDF) yang terdiri dari gabungan antara masukan (x) dan keluaran (y) untuk menentukan nilai y yang memiliki nilai probabilitas paling besar berdasarkan *training vector*. Perhitungan berdasarkan metode numerik ditulis dalam (6) dan (7) [13].

$$\hat{f} = \frac{\sum_{i=1}^n y^i \exp\left(-\frac{D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (6)$$

$$D_i^2 = (x - x^i)^T (x - x^i) \quad (7)$$

Untuk nilai *spread* (σ) yang lebih kecil, maka *radial basis function* di GRNN akan bertambah curam, sehingga neuron dengan *weight factor* yang paling dekat dengan input akan memiliki porsi keluaran yang lebih besar daripada neuron lainnya. Jaringan cenderung merespon dengan *target vector* yang dipengaruhi oleh *input vector* terdekat.

Semakin bertambah suatu *spread*, maka kemiringan dari *radial basis function* akan berkurang dan akibatnya respon terhadap *input vector* cenderung diberikan oleh lebih dari satu *neuron*. Respon yang diberikan seolah-olah jaringan mengambil rerata dari *target vector*. *Spread* yang bertambah besar akan menyebabkan semakin banyak *neuron* yang berkontribusi terhadap nilai rerata tersebut dan fungsi jaringan bertambah luas (*smooth*). Nilai *spread* yang kecil akan cenderung cocok dengan data yang sifatnya fluktuatif, tapi memiliki bentuk fungsi yang kurang *smooth*.

METODE PENELITIAN

Penelitian ini terdiri atas 3 tahap yaitu :

1. *Pre-processing* yaitu akuisisi data lalu mengklasifikasi menjadi data training dan data pengujian.
2. *Processing* yaitu pembentukan jaringan RBF-NN dan GRNN, optimasi bobot oleh AG dan AGA tipe II.
3. *Post processing* yaitu pengujian model RBF-NN, RBF-NN dengan optimasi AG/AGA dan GRNN.

A. Akuisisi dan Pengolahan Data

Akuisisi data meliputi langkah-langkah sebagai berikut.

- a. Masuk ke dalam terminal MT4 Liteforex.
- b. Pilih *tools*, masuk ke *History Centre* kemudian memilih data EUR/USD *daily* dan klik Export (format csv).
- c. Data tersebut dibuka dengan MS Excel, diambil *daily high* dan *daily low* sehingga mendapatkan 1000 data training dan 300 data pengujian. Data ini lalu ditransfer menjadi variabel di MATLAB.

Data tanggal 20 Oktober 2009 hingga 22 Agustus 2013 menjadi data training, sementara data tanggal 23 Agustus 2013 hingga 17 Oktober 2014 menjadi data pengujian.

B. Pembentukan Cluster dan Pemodelan RBF-NN

Pembentukan *cluster* menggunakan bantuan fungsi bawaan dari MATLAB yaitu *kmeans()* dan mewakili jumlah *cluster* yang akan dibentuk yaitu 2 hingga 5 *cluster*. Keluaran dari fungsi ini yaitu nilai *centre* akan dimasukkan ke dalam fungsi basis RBF-NN.

Selanjutnya adalah pembentukan matrik ϕ dan t sebagai berikut.

- a. Kolom pada matrik ϕ disesuaikan dengan jumlah *cluster* sementara baris diisi dengan data training dari urutan pertama hingga 999. Misalnya, jika data pertama bernilai 1,2837 dan data kedua 1,2845, pusat *cluster* pertama adalah 1,2500 dan pusat *cluster* kedua adalah 1,2600. Maka matrik ϕ yang dibentuk dari 2 data awal ini adalah :

$$\left[\exp\left(-\frac{\|1.2837 - 1.2500\|^2}{2\sigma^2}\right) \exp\left(-\frac{\|1.2845 - 1.2600\|^2}{2\sigma^2}\right) \right]$$

nilai σ diambil sama dengan 1, menunjukkan fungsi Gaussian dengan radial senilai dengan 1.

- b. Data pada matrik t diisi dengan data training mulai dari urutan kedua hingga 1000. Dari poin a di atas, maka matrik t yang terbentuk adalah : [1,2845]. Matrik t disusun dari data urutan kedua hingga urutan seribu. Setelah Matrik t terbentuk maka nilai bobot w dihitung melalui (2).
- c. Setelah itu matrik ϕ dan matrik w akan dikalikan untuk mendapatkan hasil yang dijadikan hasil peramalan sistem dan matrik t menjadi targetnya. Penghitungan *error* (MAPE) sesuai (5), dapat dinyatakan dalam contoh sebagai berikut. Jika hasil peramalan ke-1 hingga ke-5: 1,1 ; 1,2 ; 1,3 ; 1,4 ; 1,5 dan nilai pada matrik t : 1,2 ; 1,2 ; 1,3 ; 1,2 ; 1,5, maka nilai MAPE :

$$MAPE = \left(\frac{100}{5}\right) \left[\left| \frac{1,2-1,1}{1,2} \right| + \left| \frac{1,2-1,2}{1,2} \right| + \left| \frac{1,3-1,3}{1,3} \right| + \left| \frac{1,2-1,4}{1,2} \right| + \left| \frac{1,5-1,5}{1,5} \right| \right]$$

$$MAPE = 0,2778.$$

- d. Proses yang sama juga berlaku pada *cluster* lain. Yang berubah adalah dimensi matrik ϕ dan matrik w yang digunakan.

C. Optimasi melalui AG/AGA

Pertama-tama elemen dari matrik w diambil untuk membentuk kromosom, dengan bantuan bilangan acak sehingga membentuk 100 elemen.

Misalnya terbentuk matrik w pada 2 *cluster* sebagai berikut:

$$\begin{bmatrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & \dots & 100 \\ 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & \dots & 100 \end{bmatrix}$$

Aturan untuk proses *crossover* telah ditentukan sebelumnya. Misalnya dalam hal ini, mengganti bobot 91 hingga 100 dengan bobot 1 hingga 10. Kemudian berdasarkan bilangan acak, maka bobot 91 hingga 100 yang telah menjadi elemen matriks diberikan tanda negatif. Matrik w kini menjadi :

$$\begin{bmatrix} 1 & \dots & 1,2 & 13 & 0,34 & 1,52 & 5,33 & 4 & 1,37 & 2,31 & -2,9 & 3,1 \\ 1 & \dots & 1,2 & 13 & 0,34 & 1,52 & 5,33 & 4 & 1,37 & 2,31 & -2,9 & 3,1 \end{bmatrix}$$

Aturan untuk proses mutasi juga telah ditentukan di awal. Pada kasus ini mutasi mengalikan elemen 91 hingga 100 dengan bilangan acak dan dengan 100. Matrik w kini menjadi:


$$\begin{bmatrix} 1 & \dots & 0,24 & 2,22 & 3,34 & 4,87 & 1,53 & 2,62 & 0,70 & 1,43 & -1,29 & 0,45 \\ 1 & \dots & 0,19 & 2,24 & 3,14 & 4,90 & 1,52 & 2,62 & 0,75 & 1,44 & -1,21 & 0,65 \end{bmatrix}$$

Matrik w ini kemudian dimasukkan dalam skema RBF-NN untuk mendapatkan nilai MAPE. Demikian proses ini berulang hingga mencapai batasnya yaitu 50 *epoch*.

Proses AGA berbeda di bagian *crossover* dan mutasi. Nilai *fitness* dari masing-masing kromosom harus dicari dengan mencari nilai MAPE terlebih dahulu. Penghitungan untuk mutasi juga dilakukan dengan cara yang sama.

D. Proses Pengujian dan Peramalan GRNN


Proses pengujian dilakukan dengan matrik w dan ϕ yang dihasilkan proses training namun matrik yang digunakan diisi dengan data pengujian. Skemanya diberikan pada Gambar 2. Peneliti ini menambahkan proses peramalan GRNN setelah selesainya pencarian bobot melalui algoritma genetika.



Gambar 2. Algoritma Pengujian

Struktur GRNN dibentuk dengan bantuan fungsi bawaan MATLAB, pertama-tama menggunakan data training. Dari struktur GRNN yang terbentuk, maka pengujian dilanjutkan dengan memasukkan data pengujian untuk menghitung MAPE.

Smoothing factor atau *spread* (σ) merupakan parameter yang sangat penting dalam GRNN dan ditentukan secara empiris [12]. Berdasarkan percobaan pada data testing dengan nilai *spread* antara 0,01 hingga 0,1 maka diambil nilai *spread* terbaik yaitu 0,01. Grafik pengujian nilai *spread* ditunjukkan pada Gambar 3 dengan sumbu x menunjukkan *spread* yang diuji dan sumbu y menunjukkan nilai error dalam MSE (*mean square error*).



Gambar 3. Grafik Pengujian Spread

Penulis menggunakan data MAPE untuk RBF-NN murni dengan 2 hingga 5 *cluster* dari penelitian sebelumnya. Data berikutnya yang diambil adalah nilai MAPE untuk RBF-NN yang telah dioptimasi dengan AG tipe II dan AGA tipe II. Nilai MAPE terakhir dihasilkan dari hasil pengujian dengan metode GRNN. Perbandingan dilakukan untuk seluruh nilai MAPE tersebut dan metode peramalan dengan nilai MAPE terkecil dianggap sebagai yang terbaik.

HASIL DAN ANALISIS

Hasil percobaan untuk data *daily low* dan *daily high* ditunjukkan pada Tabel I dan Tabel II.

TABEL 1. Rangkuman Mape Untuk Data Daily Low

CLUSTER	METODE	NILAI MAPE
2	RBF-NN	0,2850
	RBF+AG	0,2661
	RBF+AGA	0,2656
	GRNN	0,3448
3	RBF-NN	0,2297
	RBF+AG	0,2290
	RBF+AGA	0,2289
	GRNN	0,2497
4	RBF-NN	0,2299
	RBF+AG	0,2289
	RBF+AGA	0,2289
	GRNN	0,2494
5	RBF-NN	0,2305
	RBF+AG	0,2292
	RBF+AGA	0,2288
	GRNN	0,2490

TABEL 2. Rangkuman Mape Untuk Data Daily High


CLUSTER	METODE	NILAI MAPE
2	RBF-NN	0,2950
	RBF+AG	0,2766
	RBF+AGA	0,2814
	GRNN	0,3394
3	RBF-NN	0,2195
	RBF+AG	0,2194
	RBF+AGA	0,2193
	GRNN	0,2380
4	RBF-NN	0,2197
	RBF+AG	0,2198
	RBF+AGA	0,2197
	GRNN	0,2376

5	RBF-NN	0,2200
	RBF+AG	0,2197
	RBF+AGA	0,2198
	GRNN	0,2373

Dari hasil percobaan terlihat bahwa nilai MAPE dari GRNN lebih besar daripada metode RBF-NN dan RBF-NN yang dioptimasi dengan algoritma genetika. Nilai MAPE terkecil untuk GRNN sebesar 0,2373% pada struktur 5 *cluster* data *daily high* dan nilai MAPE terbesar sebesar 0,3448% pada struktur 2 *cluster* data *daily low*. Data testing forex dan data peramalan GRNN untuk nilai MAPE tersebut diberikan pada Gambar 4 dan 5.



Gambar 4 . Kurva Peramalan GRNN 2 *cluster* *daily low*



Gambar 5. Kurva Peramalan GRNN 5 *cluster* *daily high*

Dari grafik terlihat bahwa peramalan pada GRNN 2 *cluster* di data *daily low* belum cukup dekat dengan data forex aktual, seperti terlihat pada GRNN 5 *cluster* di data *daily high*.

Hal ini menunjukkan metode peramalan dengan GRNN belum memberikan hasil yang lebih baik daripada metode yang lain. Pencarian di dekat bobot RBF-NN seperti yang dilakukan oleh algoritma genetika terbukti lebih efektif daripada

pendekatan fungsi GRNN menggunakan *spread* kecil pada kasus mata uang EUR/USD.

GRNN memerlukan proses komputasi tambahan seperti *clustering*, seperti yang dicobakan pada penelitian ini, dalam mengevaluasi suatu data baru [9]. Dari hasil terlihat bahwa penambahan jumlah *cluster* berpengaruh terhadap nilai MAPE dari GRNN, yaitu menurunkan nilai MAPE.

GRNN memiliki keuntungan yang signifikan yaitu membutuhkan waktu yang lebih singkat dalam proses peramalan namun dengan mengorbankan akurasi. Pada data yang besar dan fluktuatif, disarankan untuk menambahkan pendekatan algoritma genetika ke dalam desain *neural network* [14].

KESIMPULAN

Kesimpulan yang diperoleh dari penelitian ini adalah : peramalan dengan GRNN untuk data forex EUR/USD belum mampu memberikan nilai MAPE yang lebih baik dibandingkan dengan metode RBF-NN dan metode RBF-NN dengan optimasi algoritma genetika/algoritma genetika adaptif. Hal ini berlaku baik pada data *daily high* dan *daily low*.

DAFTAR PUSTAKA

- Huda, F. A., Ridok. A., Dewi. C., 2013, Peramalan Time Series Saham Menggunakan Backpropagation Neural Network Berbasis Algoritma Genetika, Teknik Informatika PTIIK, Universitas Brawijaya.
- Bank for International Settlements, 2014. Triennial Central Bank Survey. Monetary and Economic Department.
- Georgios Sermpinis, Konstantinos Theofilatos, Andreas Karathanasopoulos, Efstratios F. Georgopoulos, Christian Dunis, 2012. Forecasting Foreign Exchange Rates with Adaptive Neural Networks Using Radial-Basis Functions and Particle Swarm Optimization. *European Journal Operation Research* 225, 528–540. doi:http://dx.doi.org/10.1016/j.ejor.2012.10.020
- Zuliana, S.U., 2012. Penerapan Global Ridge-Regression Pada Peramalan Data Time Series Non Linear Studi Kasus : Pemodelan Nilai Tukar US Dollar Terhadap Rupiah. Kaunia VIII
- Warda, S. M., Irhamni F., 2012. Analisa Data Antar Pos Express Menggunakan Metode Radial Basis Function Neural Network (RBF-NN) Study PT. POS Indonesia (Persero) Surabaya. Universitas Trunojoyo.
- Maillard, E.P., Gueriot, D., 1997. RBF neural network, basis functions and genetic algorithm, in: *International Conference on Neural Networks*, 1997. Presented at the *International Conference on Neural Networks*, 1997, pp. 2187–2192 vol.4. doi:10.1109/ICNN.1997.614247
- Wiharto, Y.S. Palgunadi, Muh Aziz Nugroho, 2013. Analisis Penggunaan Algoritma Genetika Untuk Perbaikan Jaringan Syaraf Tiruan Radial Basis Function. *Seminar Nasional Teknologi Informasi Dan Komunikasi 2013*. SENTIKA 2013.
- Gautama, N.W., Dharma, A., Sudarma, M., 2016. Analisis Metode Rbf-Nn Dengan Optimasi Algoritma Genetika Pada Peramalan Mata Uang EUR/USD. *Majalah Ilmiah Teknologi Elektro* 15, 107–114.
- Specht, D.F., 1991. A General Regression Neural Network. *IEEE Transactions on Neural Network*. 2, 568–576. doi:10.1109/72.97934
- Heriyanto, D. N., Rachman, F.H., Satoto, B.D., 2013. Penerapan Metode Radial Basis Function Network dengan K-Means Cluster untuk Peramalan Kebutuhan Straw. *Jurnal Sarjana Teknik Informatika*. Universitas Trunojoyo Madura 1, 1–10.
- Andreasson, N., Evgrafov, A., Patriksson, M., 2006. *Introduction to Continuous Optimization: Foundations and Fundamental Algorithms*, 1st edition. Studentlitteratur AB.
- Dharma, A., Robandi, I., Purnomo, M.H., 2011. Application of Interval Type-2 Fuzzy Logic System in Short Term Load Forecasting on Special Days. *IPTEK Journal for Technology and Science* 22. doi:10.12962/j20882033.v22i2.65
- Gang Sun, Steven J Hoff, Brian C Zelle, Minda A Smith, 2008. Development and Comparison of Backpropagation and Generalized Regression Neural Network Models to Predict Diurnal and Seasonal Gas and PM10 Concentrations and Emissions from Swine Buildings. *American Society of Agricultural and Biological Engineers*. doi:10.13031/2013.25180

Yazıcı, G., Polat, Ö., Yıldırım, T., 2006. Genetic Optimizations for Radial Basis Function and General Regression Neural Networks, in: Gelbukh, A., Reyes-Garcia, C.A. (Eds.), MICAI 2006: Advances in Artificial

Intelligence, Lecture Notes in Computer Science. Presented at the Mexican International Conference on Artificial Intelligence, Springer Berlin Heidelberg, pp. 348–356.