

# OPTIMASI GENERAL REGRESSION NEURAL NETWORK DENGAN FRUIT FLY OPTIMIZATION ALGORITHM UNTUK PREDIKSI PEMAKAIAN ARUS LISTRIK PADA PENYULANG

Ni Putu Novita Puspa Dewi<sup>1,2)</sup>, Robertus Adi Nugroho<sup>2)</sup>

<sup>1)</sup> Program Studi Ilmu Komputer, Jurusan Teknik Informatika, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha, Singaraja, Bali, Indonesia

<sup>2)</sup> Program Studi Informatika, Jurusan Informatika, Fakultas Sains dan Teknologi, Universitas Sanata Dharma, Sleman, Daerah Istimewa Yogyakarta, Indonesia

Corresponding Author: [niputunovitapuspawedewi@gmail.com](mailto:niputunovitapuspawedewi@gmail.com)

## Abstrak

Prediksi pemakaian arus listrik yang akurat pada setiap penyulang listrik sangat penting untuk memastikan distribusi listrik berjalan lancar. Hasil prediksi pemakaian listrik dapat digunakan untuk mengetahui berapa banyak produksi listrik yang harus dilakukan demi memenuhi kebutuhan listrik secara menyeluruh. Model prediksi hybrid yang menggabungkan General Regression Neural Network (GRNN) dan algoritma optimasi Fruit Fly Optimization Algorithm (FOA) diusulkan untuk menghasilkan prediksi arus listrik yang akurat dan stabil. FOA digunakan untuk mengoptimasi GRNN untuk menemukan nilai smoothing parameter optimal. Data time-series dari 5 penyulang yang mendistribusikan listrik pada 5 wilayah berbeda digunakan untuk validasi model yang diusulkan. Hasil pengujian menunjukkan bahwa model hybrid FOAGRNN menghasilkan error, ketahanan, dan generalisasi yang lebih baik dalam prediksi ini jika dibandingkan dengan model GRNN saja. Pada pengujian terhadap 5 data testing, FOAGRNN menghasilkan error prediksi lebih kecil yaitu rata-rata Root Mean Square Error sebesar 6,98411 dan Mean Absolute Error 3,44542 dibandingkan GRNN dengan rata-rata error secara berturut-turut 7,86073 dan 4,21529.

**Kata kunci:** FOA; GRNN; prediksi; time-series; optimasi parameter

## Abstract

Accurate prediction of electric current usage at each electricity feeder is very important to ensure the distribution of electricity runs smoothly. The results of the prediction can be used to find out how much electricity production must be done to meet the overall demand for electricity. A hybrid prediction model that combines the General Regression Neural Network (GRNN) and the Fruit Fly Optimization Algorithm (FOA) optimization algorithm is proposed to produce an accurate and stable electric current prediction. FOA is used to optimize GRNN to find optimal smoothing parameter values. Time-series data of 5 feeders that distribute electricity in 5 different regions are used to validate the proposed model. The experimental results show that the hybrid FOAGRNN model produces small error, good robustness, and better in generalization than the GRNN one. In testing with 5 different testing data, FOAGRNN produced smaller prediction errors, namely an average Root Mean Square Error of 6.98411 and a Mean Absolute Error of 3.44542 compared to GRNN with an average error of 7.86073 and 4.21529 respectively.

**Keywords:** FOA; GRNN; prediction; time-series; parameter optimization

## 1. Pendahuluan

Di negara berkembang seperti Indonesia, menjaga ketersediaan dan kualitas pasokan tenaga listrik dibutuhkan untuk mendukung pembangunan secara berkelanjutan. Prediksi untuk berbagai keperluan di bidang energi terbarukan telah menjadi topik penelitian yang aktif hingga saat ini. Informasi yang terpercaya berkaitan hal tersebut memungkinkan operasional yang aman dan membantu meminimalkan biaya operasional sumber daya energi di masa depan [1]. Pada

penelitian ini, prediksi pemakaian arus listrik pada penyulang diperlukan untuk mengetahui kebutuhan pemakaian dan memastikan distribusi jaringan listrik yang lancar. Beberapa model tradisional telah diusulkan untuk prediksi seputar masalah kelistrikan. Sebagai contoh, *Support Vector Machine* (SVM) digunakan sebagai model prediksi listrik di beberapa studi sebelumnya [2]–[5]. Syafruddin dan Hakim menggunakan regresi linier untuk memprediksi kebutuhan listrik jangka panjang [6]. *Support Vector Regression* (SVR) juga digunakan untuk memprediksi konsumsi listrik bulanan [7].

Dengan latar belakang perkembangan teknologi kecerdasan buatan, dirasa lebih signifikan untuk memprediksi pemakaian arus listrik dengan menggunakan metode *intelligent prediction*. Dalam penelitian ini, diusulkan *General Regression Neural Networks* (GRNN) sebagai model prediksi. Model ini termasuk dalam *Radial Basis Neural Network*. Pada tahun 2000, Leung, dkk. menunjukkan bahwa dasar operasi GRNN didasarkan pada teori regresi non-linear (kernel) di mana estimasi nilai output yang diharapkan ditentukan oleh set input [8]. GRNN diketahui mampu menjelaskan keberadaan hubungan data lebih cepat dan tidak memerlukan asumsi data [9]. GRNN tidak memerlukan sejumlah besar iterasi dalam memperkirakan *weight* dan jumlah unit dalam *pattern layer* [10].

GRNN telah menunjukkan kinerja yang baik pada prediksi saham dan ketebalan lapisan *ic* pada saluran transmisi listrik. Caraka, dkk. menyatakan bahwa GRNN mampu memprediksi nilai kerugian terendah dan laba tertinggi pada data *return* indeks harga saham CFD (*Contract For Difference*) Euro 50 [10]. GRNN juga terbukti mengungguli metode statistik ARIMA untuk memprediksi IHSG (Indeks Harga Saham Gabungan) untuk beberapa periode berikutnya [9]. GRNN juga telah menunjukkan kinerja prediksi yang baik untuk memperkirakan ketebalan lapisan *ic* ada jalur transmisi listrik di waktu dan tempat yang berbeda [11]. Namun, nilai *smoothing parameter* pada GRNN perlu diatur untuk memperoleh kinerja yang baik. Proses pengaturan nilai *smoothing parameter* ini dapat dilakukan secara manual dengan *handtuning* atau dilakukan secara otomatis dengan menerapkan metode optimasi.

*Swarm intelligence* baru-baru ini telah diterapkan untuk mengoptimalkan model prediksi. Sebagai contoh, *Particle Swarm Optimization* (PSO) digunakan untuk mengoptimalkan *Radial Basis Function Neural Network* (RBFNN) dengan memperbaiki *center width* pada fungsi aktivasi *hidden layer* dan bobot pada *output layer* [12]. Algoritma ini juga digunakan untuk mengoptimalkan *Feed Forward Neural Network* [13]. Algoritma optimasi *swarm intelligence* penting lainnya adalah *Fruit Fly Optimization Algorithm* (FOA) yang mengadopsi perilaku pencarian makanan oleh kumpulan lalat buah. Metode ini memerlukan *setting* parameter yang tidak terlalu banyak dan bekerja pada kecepatan yang relatif tinggi untuk pencarian optimal dengan pengaplikasian yang luas [14]. FOA berhasil digunakan dalam memprediksi kesulitan keuangan perusahaan di Taiwan [15]. Pada tahun 2012, Li, dkk. mengajukan *Least Squares Support Vector Machine* (LSSVM) yang dioptimalkan oleh FOA sebagai model prediksi beban listrik tahunan dan model yang diusulkan ini memperoleh efektivitas prediksi yang lebih baik dibandingkan dengan LSSVM yang dioptimasi oleh *Coupled Simulated Annealing Algorithm* (CSA) [16].

Dalam penelitian ini, model *hybrid* dari GRNN dan FOA digunakan sebagai model prediksi. FOA digunakan untuk menemukan nilai *smoothing parameter* optimal untuk GRNN. Selain itu, GRNN tanpa optimasi akan disimulasikan juga sebagai metode perbandingan yang digunakan untuk memvalidasi keefektifan model *hybrid* yang diusulkan.

## 2. Metode Penelitian

Beberapa hal yang akan dibahas dalam metode penelitian adalah model prediksi, dataset, *setup* eksperimen, dan pengukuran kinerja model. Terdapat 2 model yang digunakan untuk memprediksi arus listrik terpakai pada penyulang, yaitu GRNN dan GRNN yang dioptimasi oleh FOA (FOAGRNN). Secara berurutan subbab 2.1. menjelaskan mengenai GRNN; subbab 2.2. menjelaskan mengenai FOAGRNN; subbab 2.3. menjelaskan tentang dataset; subbab 2.4. menjelaskan mengenai pengaturan untuk eksperimen dan pengukuran kinerja model menggunakan *metric* performa untuk prediksi.

### 2.1. GRNN

Arsitektur GRNN ditunjukkan pada Gambar 1. Arsitektur GRNN terdiri dari 4 layer pemroses:

*input layer*, *pattern layer*, *summation layer*, dan *output layer*. Merujuk Gambar 1,  $Y$  merupakan luaran (*output*) prediksi yang dihasilkan dari input  $X$  berupa *input vector*. Dalam hal ini, *input vector* dapat terdiri dari sejumlah  $q$  variabel prediktor. *Input layer* menerima *input vector*  $X$  dan meneruskannya ke *pattern layer*. *Pattern layer* menggunakan transformasi nonlinear untuk menghitung nilai (*weight*) untuk setiap *training data point*. *Transfer function* dari *neuron* ke- $i$  pada *pattern layer* ( $P_i$ ) ditunjukkan pada persamaan (1) [11]:

$$P_i = \exp\left(\frac{-D_i^2}{2\sigma^2}\right), \text{ dimana } i = 1, 2, 3, \dots, n \tag{1}$$

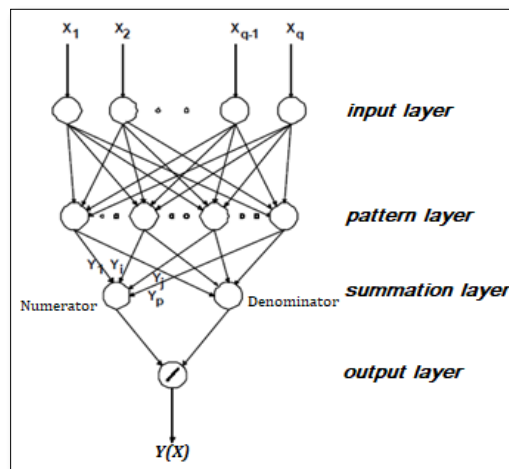
Jarak antara sampel *training* dan data poin yang menunjukkan nilai prediksi, dalam hal ini dinyatakan sebagai  $D_i$ , digunakan untuk mengukur seberapa bagus setiap sampel *training* dapat merepresentasikan sampel prediksi dari  $X$  [14]. Nilai  $\sigma$  adalah *smoothing parameter*. Nilai dari  $D_i$  dihitung pada persamaan (2) berikut ini:

$$D_i = (X - X_i)^T \cdot (X - X_i) \tag{2}$$

dapat dijelaskan bahwa  $X$  merupakan *input vector*;  $X_i$  adalah sampel pembelajaran (*learning sample*) terhadap *neuron* ke- $i$ .

*Neuron* ke- $i$  pada *pattern layer* mengkalkulasikan *ouput* dari  $P_i$  (*weight* untuk sampel  $X_i$ ) lalu mengirimkan hasilnya ke *summation layer*. *Neuron* pada *summation layer* terdiri dari 2 yaitu *numerator* dan *denominator*. *Numerator* menghitung *weighted sum* dari *output* untuk semua *training sample points*, sedangkan *denominator* menghitung sum dari semua *weight*. Fungsi objektif  $Y(X)$  pada *output layer* merupakan pembagian antara *numerator* dan *denominator* [11]:

$$Y(X) = \frac{\sum_i^n Y_i P_i}{\sum_i^n P_i} \tag{3}$$



Gambar 1. Arsitektur dari GRNN [17]

## 2.2. FOAGRNN

*Fruit Fly Optimization Algorithm* (FOA) diusulkan oleh Pan pada tahun 2011. Tujuan dari algoritma ini adalah untuk mengoptimalkan fungsi tujuan (*objective function*) berdasarkan perilaku lalat buah menemukan makanannya [15]. Seperti diilustrasikan pada Gambar 2, FOAGRNN dibangun dengan mengintegrasikan GRNN dan FOA.

Proses yang lebih rinci untuk menemukan *smoothing parameter* dijelaskan dalam area garis putus-putus pada Gambar 2. Proses dimulai dengan memuat dataset, melakukan proses *data preprocessing*, dan membagi dataset menjadi dataset *training* dan *testing*. *Data preprocessing* terdiri dari *treatment* terhadap *missing data*, normalisasi data ke dalam kisaran 0-1, dan *reframing* data ke dalam bentuk *input sequence* (*input vector*). Setelah model GRNN dibangun, proses

optimasi untuk menemukan *smoothing parameter* dengan FOA dimulai. Proses optimasi akan dihentikan setelah mencapai iterasi yang ditentukan. Hasil proses ini berupa *smoothing parameter* yang optimal untuk kemudian digunakan kembali oleh GRNN sebagai model prediksi terbaik. Model ini kemudian dievaluasi dengan menghitung Root Mean Squared Error (RMSE) dan Mean Absolute Error (MAE) dari dataset *testing*.

Langkah-langkah dari proses optimasi model FOAGRNN (area dalam garis putus-putus) pada Gambar 2 dijelaskan sebagai berikut:

1. Inisialisasi iterasi maksimum (*maxgen*) dan ukuran populasi (*sizepop*) dari lalat buah. *Sizepop* diatur sebanyak *n*, dimana *n* adalah bilangan bulat positif.
2. Inisialisasi koordinat  $X, Y$  untuk lokasi awal kumpulan lalat buah.

$$X_0 = \text{RandomValue} \quad (4)$$

$$Y_0 = \text{RandomValue} \quad (5)$$

3. Set nilai random untuk arah terbang masing-masing lalat buah, di mana  $i = 1, 2, 3, \dots, n$ :

$$X_i = X_0 + \text{RandomValue} \quad (6)$$

$$Y_i = Y_0 + \text{RandomValue} \quad (7)$$

4. Menghitung jarak  $Dist_i$  dari lalat buah ke- $i$  ke koordinat asal, dan menggunakan nilai tersebut untuk menemukan nilai penentuan konsentrasi bau  $S_i$ :

$$Dist_i = \sqrt{X_i^2 + Y_i^2} \quad (8)$$

$$S_i = \frac{1}{Dist_i} \quad (9)$$

5. Nilai  $S_i$  akan diambil sebagai *smoothing parameter* yang digunakan oleh model GRNN. RMSE yang dihitung pada proses pelatihan GRNN dikembalikan sebagai nilai  $Smell_i$ . Nilai  $Smell_i$  dianalogikan sebagai nilai yang menentukan seberapa baik konsentrasi bau pada setiap lalat buah.

$$Smell_i = \text{GRNN}(S_i) \quad (10)$$

6. Memilih lalat buah dengan nilai konsentrasi bau terbaik di antara kumpulan lalat buah. Penelitian ini bertujuan untuk membangun model yang memberikan hasil prediksi dengan *error* terkecil, maka optimasi bertujuan untuk menemukan nilai RMSE terkecil pula. Nilai  $bestSmell$  merupakan RMSE minimum diantara nilai  $Smell_i$  kumpulan lalat buah.

$$[bestSmell, bestIndex] = \min(Smell_i) \quad (11)$$

7. Jika nilai  $bestSmell$  lebih kecil dari RMSE minimum global saat ini ( $smellBest$ ), ganti nilai  $SmellBest$  dengan  $bestSmell$ . Set lokasi baru dari kumpulan lalat buah ke koordinat  $X, Y$  dari individu lalat buah dengan RMSE terkecil:

$$smellBest = bestSmell \quad (12)$$

$$X_0 = X(bestIndex) \quad (13)$$

$$Y_0 = Y(bestIndex) \quad (14)$$

8. Proses optimasi untuk menemukan nilai  $\sigma$  (*smoothing parameter*) terbaik untuk RMSE terkecil dilakukan dengan mengulangi langkah 3-7. Jika iterasi telah mencapai *maxgen* (iterasi maksimal) maka proses akan dihentikan.


### 2.3. Dataset

Model prediksi GRNN dan FOAGRNN dilatih dan dievaluasi dengan menggunakan 5 dataset. Kelima dataset merupakan data *time-series* pemakaian arus listrik setiap jam selama satu tahun (oktober 2017-september 2018) di wilayah PT. PLN Persero Area Kuala Kapuas. Pemakaian listrik tercatat setiap jam dalam satuan arus listrik (Ampere). Arus yang mengalir ke pelanggan disalurkan oleh 5 penyulang untuk 5 daerah berbeda.

### 2.4. Setup Pengujian dan Pelatihan Model

Dataset dibagi menjadi 11 bulan untuk *training*, 1 bulan untuk *testing*. Model prediksi dilatih

menggunakan dataset *training* lalu diuji dengan dataset *testing*. GRNN dilatih dengan FOA untuk mengoptimalkan *smoothing parameter*. Input untuk kedua model adalah dataset *training* dan *testing* dalam bentuk *input sequence* sebagai prediktor untuk menentukan target prediksi. Beberapa jenis *input sequence* diujicoba dalam penelitian ini guna melihat performa prediksi model, sehingga dapat ditentukan penggunaan *previous time-step* yang tepat sebagai prediktor. *Input sequence* yang digunakan berkisar antara penggunaan data 1 hingga 8 jam sebelumnya (nilai *previous time-step* untuk *reframing* data berkisar antara 1-8). Ini berarti untuk memprediksi sebuah data poin pada suatu waktu digunakan prediktor berupa data 1 hingga 8 jam sebelumnya.



Gambar 2. Model prediksi yang menggabungkan FOA dan GRNN (FOAGRNN)

Untuk evaluasi kinerja akhir pada dataset *testing*, model FOAGRNN dengan *smoothing parameter* optimal dan RMSE terkecil akan dipilih. Parameter pelatihan model seperti: *maxgen*, *sizpop*, dan *smoothing parameter* untuk 5 dataset akan berbeda satu dengan yang lainnya. Seperti

diketahui bahwa nilai iterasi maksimum (*maxgen*) dan ukuran dari kumpulan lalat buah (*sizepop*) mempengaruhi kinerja model [15]. Variasi nilai *maxgen* dan *sizepop* selama proses optimasi telah dilakukan untuk mengetahui nilai yang berkontribusi baik bagi proses pelatihan. Parameter final untuk proses pelatihan model FOAGRNN dijelaskan pada Tabel 1.

Tabel 1. Parameter pelatihan model FOAGRNN

Dataset	Maxgen	Sizepop
Penyulang 1	70	15
Penyulang 2	60	20
Penyulang 3	70	20
Penyulang 4	70	20
Penyulang 5	80	15

Empat jenis pengukuran kesalahan (*error*) diterapkan untuk mengevaluasi kinerja model prediksi, yaitu: Root Mean Squared Error (RMSE) pada persamaan (15), Mean Absolute Error (MAE) pada persamaan (16), Average Absolute Deviation (AbsDev) pada persamaan (17), dan Bias pada persamaan (18). Persamaan diterapkan pada *time-series* arus listrik aktual  $x$  dan *time-series* arus hasil prediksi  $x'$ . Baik  $x$  dan  $x'$  memiliki sejumlah  $N$  sampel.

$$RMSE(x', x) = \sqrt{\frac{1}{N} \sum_{i=1}^N (x'_i - x_i)^2} \tag{15}$$

$$MAE(x', x) = \frac{1}{N} \sum_{i=1}^N |x'_i - x_i| \tag{16}$$

$$AbsDev(x', x) = \frac{1}{\sum_{i=1}^N x_i} \sum_{i=1}^N |x'_i - x_i| \tag{17}$$

$$Bias = \frac{1}{N} \sum_{i=1}^N (x'_i - x_i) \tag{18}$$

### 3. Hasil dan Pembahasan

Prediksi pemakaian arus listrik pada data *time-series* penyulang dilakukan dengan menggunakan dua jenis model, yaitu FOAGRNN dan GRNN tanpa optimasi. Perbandingan dilakukan untuk mengetahui apakah proses optimasi pada FOAGRNN memberikan hasil prediksi dengan *error* lebih kecil dibandingkan dengan GRNN. Selain itu, pengaruh dari penggunaan *previous time-step* terhadap hasil prediksi juga akan disajikan.

#### 3.1. Optimasi GRNN dengan FOA

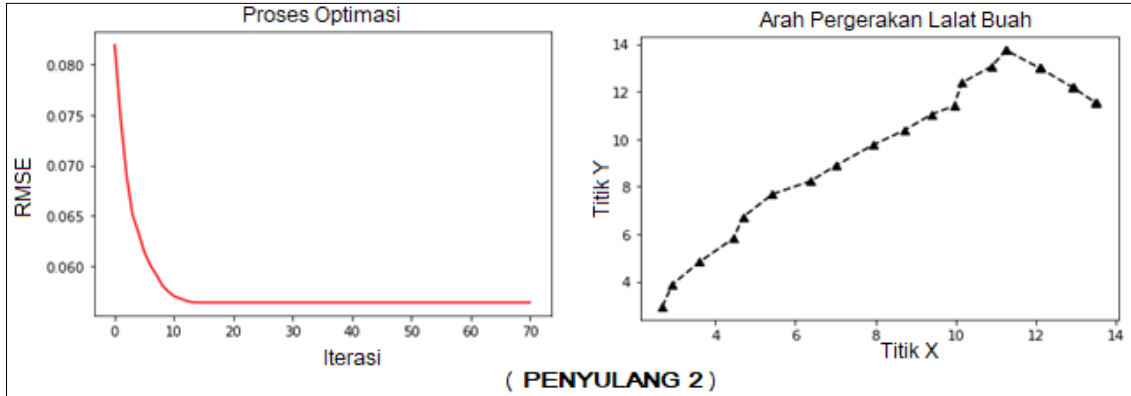
Optimasi yang dilakukan terhadap model FOAGRNN memberikan *smoothing parameter* optimal yang unik untuk setiap dataset. Terdapat 5 dataset dari 5 penyulang berbeda, sehingga *smoothing parameter* untuk model prediksi 5 penyulang pun berbeda. Proses optimasi *smoothing parameter* untuk dataset penyulang 2 dan 5 ditunjukkan pada Gambar 3 dan 4. Grafik dengan garis berwarna merah menunjukkan bahwa seiring bertambahnya iterasi pencarian *smoothing parameter*, RMSE juga mengalami penurunan. Grafik dengan garis berwarna hitam menunjukkan pergerakan lalat buah dalam proses optimasi. Grafik menunjukkan hasil dari penggunaan dataset dengan *input sequence previous time-step=7* yang memiliki nilai RMSE terbaik.

#### 3.2. Perbandingan Performa GRNN dan FOAGRNN


Untuk memverifikasi kinerja model yang diusulkan, maka kinerja FOAGRNN akan dibandingkan dengan kinerja model GRNN yang tidak dioptimalkan FOA. Ringkasan kinerja kedua model dalam melakukan prediksi dengan menggunakan data dari 5 penyulang ditunjukkan pada Tabel 2 dan 3. Angka yang bercetak tebal pada Tabel 2 dan 3 menunjukkan nilai *error* yang lebih kecil. Selanjutnya, indikator-indikator pada tabel 2 dan 3 dapat mencerminkan *overall error* dan tingkat *error dispersion* dari masing-masing model prediksi. Oleh karena itu, dapat dibuktikan

lebih lanjut bahwa efek prediksi keseluruhan dari model FOAGRNN lebih baik dari pada model GRNN.

Pengukuran kinerja prediksi pada Tabel 2 dan 3 di atas digunakan untuk menilai kekuatan prediksi. Bias memungkinkan kita menilai apakah prediksi arus listrik yang terpakai memiliki nilai lebih tinggi atau nilai lebih rendah daripada nilai aktualnya. Nilai AbsDev umumnya digunakan dalam sektor energi untuk menilai kualitas prediksi. Nilai rerata Bias dan AbsDev untuk FOAGRNN masih lebih kecil dibandingkan dengan GRNN. Namun dapat diamati bahwa hasil prediksi kedua model cenderung lebih rendah dari nilai aslinya.



Gambar 3. Proses optimasi FOAGRNN untuk dataset Penyulang 1; RMSE data normalisasi



Gambar 4. Proses optimasi FOAGRNN untuk dataset Penyulang 5; RMSE data normalisasi


Tabel 2. Kinerja model FOAGRNN dan GRNN pada dataset *training*

Data	FOAGRNN				GRNN			
	RMSE	MAE	AbsDev	BIAS	RMSE	MAE	AbsDev	BIAS
Penyulang 1	5,21984	3,17113	0,17454	-0,17060	6,11610	4,01387	0,22093	-0,45333
Penyulang 2	4,80244	3,16389	0,02827	-0,00041	8,11274	6,07558	0,05429	-0,13038
Penyulang 3	7,31794	4,31562	0,05589	-0,00857	8,70744	5,76488	0,07466	0,05471
Penyulang 4	7,96027	4,93417	0,05359	-0,04632	10,37977	7,15905	0,07776	-0,15966
Penyulang 5	2,55031	1,64227	0,03119	-0,00125	3,77664	2,79070	0,05300	-0,05450
<b>Average</b>	<b>5,57016</b>	<b>3,44542</b>	<b>0,06870</b>	<b>-0,04543</b>	<b>7,41854</b>	<b>5,16082</b>	<b>0,09613</b>	<b>-0,14863</b>

Tabel 3. Kinerja model FOAGRNN dan GRNN pada dataset *testing*


Data	FOAGRNN				GRNN			
	RMSE	MAE	AbsDev	BIAS	RMSE	MAE	AbsDev	BIAS
Penyulang 1	<b>7,54066</b>	<b>4,27658</b>	<b>0,22087</b>	<b>-0,34508</b>	7,91124	4,76191	0,24592	-0,79787
Penyulang 2	<b>6,35903</b>	<b>4,28856</b>	<b>0,03881</b>	<b>0,35683</b>	8,09162	6,16962	0,05583	0,43716
Penyulang 3	<b>9,17189</b>	<b>5,02999</b>	<b>0,06202</b>	<b>-1,35774</b>	9,79765	6,03824	0,07446	-1,94505
Penyulang 4	<b>8,54747</b>	<b>5,39303</b>	<b>0,05720</b>	<b>-1,01299</b>	9,74678	6,66182	0,07066	-1,36844
Penyulang 5	<b>3,30152</b>	<b>2,08828</b>	<b>0,04074</b>	<b>0,34911</b>	3,75635	2,82590	0,05513	0,40273
<b>Average</b>	<b>6,98411</b>	<b>4,21529</b>	<b>0,08393</b>	<b>-0,40197</b>	7,86073	5,29150	0,10040	-0,65429

Perbandingan kinerja model prediksi FOAGRNN dan GRNN juga ditampilkan pada Gambar 5-8. FOAGRNN dapat mengikuti pola pergerakan data aktual lebih baik dibandingkan dengan GRNN. Pergerakan RMSE dari kedua model prediksi dengan penggunaan 1 hingga 8 *previous time-step* baik pada penerapannya terhadap dataset *training* maupun dataset *testing* ditunjukkan pada Gambar 9 dan 10. Berdasarkan percobaan penggunaan 1 hingga 8 *previous time-step* yang ditunjukkan pada gambar 9 dan 10, dapat diketahui jika semakin besar nilai *previous time-step* yang digunakan maka semakin baik bagi kinerja model. Bersamaan dengan hasil pada Tabel 2 dan 3 dapat disimpulkan bahwa nilai RMSE, MAE, AbsDev, dan Bias dari FOAGRNN masih lebih rendah dibandingkan dengan model GRNN. Terbukti bahwa model yang diusulkan memperoleh akurasi prediksi tertinggi dan stabilitas terbaik dalam kondisi yang berbeda. Singkatnya, GRNN yang dioptimalkan dengan FOA secara efektif dapat mengurangi tingkat *error* prediksi untuk kelima penyulang.




Gambar 5. Grafik perbandingan data prediksi dan aktual pada dataset *testing* Penyulang 1






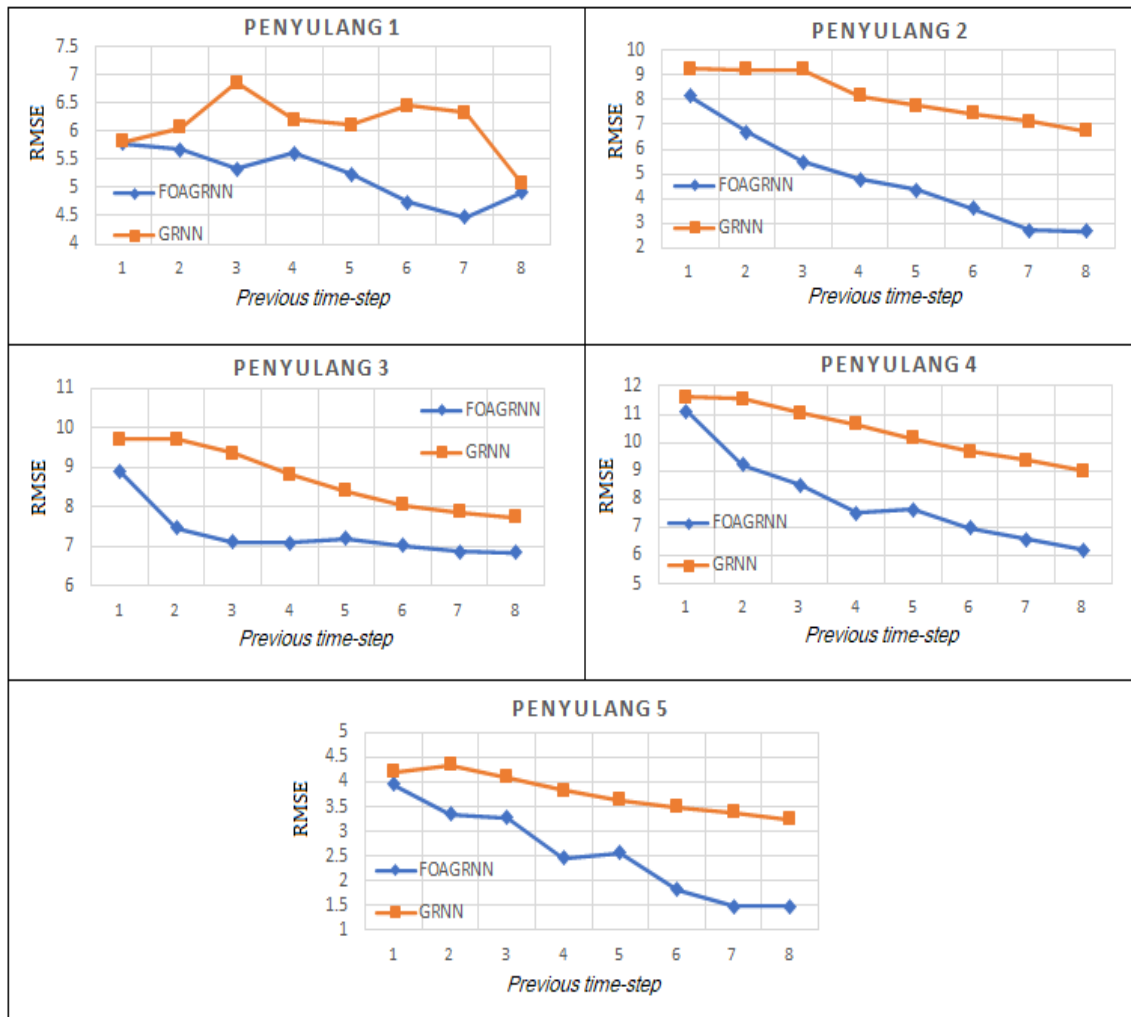
Gambar 6. Grafik perbandingan data prediksi dan aktual pada dataset *testing* Penyulang 5




Gambar 7. Grafik perbandingan data prediksi dan aktual pada dataset *testing* Penyulang 2



Gambar 8. Grafik perbandingan data prediksi dan aktual pada dataset *training* Penyulang 5



Gambar 9. Pergerakan RMSE pada proses *training* dengan menggunakan variasi *input sequence* 1 hingga 8 *previous time-step*



Gambar 10. Pergerakan RMSE pada dataset *testing* dengan menggunakan variasi *input sequence* 1 hingga 8 *previous time-step*

#### 4. Kesimpulan

Penelitian ini menyajikan model prediksi *hybrid* untuk memperikarakan besarnya arus listrik terpakai dengan menggabungkan GRNN yang dioptimalkan oleh FOA. FOA diadopsi untuk mengoptimalkan *smoothing parameter* GRNN. Diketahui bahwa *smoothing parameter* merupakan parameter yang menentukan kinerja model prediksi. Penentuan nilai *smoothing parameter* secara manual merupakan pekerjaan *hand tuning* yang memakan waktu cukup lama. Sehingga algoritma FOA sangat membantu dalam menemukan nilai tersebut secara efektif.

Beberapa kesimpulan berdasarkan hasil penelitian adalah sebagai berikut: (1) algoritma optimasi FOA menambah kemampuan pencarian global yang cukup kuat untuk model prediksi dan model GRNN yang dioptimalkan oleh FOA menunjukkan kinerja yang baik; (2) berdasarkan penilaian terhadap *error* prediksi, FOAGRNN adalah model prediksi yang lebih menjanjikan untuk prediksi arus listrik terpakai pada kelima penyulang jika dibandingkan dengan model GRNN; (3) menurut analisa dari hasil prediksi 5 penyulang pada 5 daerah berbeda, ditemukan bahwa model yang diusulkan dalam penelitian ini memiliki kinerja prediksi yang baik. Oleh karena itu, metode prediksi yang diusulkan (model FOAGRNN) layak dan dapat menjadi alternatif yang efektif untuk prediksi di industri tenaga listrik.

## Referensi

- [1] A. Gensler, J. Henze, B. SickRaabe, dan N. Raabe, "Deep Learning for Solar Power Forecasting – An Approach Using Autoencoder and LSTM Neural Networks," pada *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC 2016)*, 2016, pp. 2858–2865.
- [2] S. Grubwinkler dan M. Lienkamp, "Energy Prediction for EVs Using Support Vector Regression Methods Stefan," pada *7th IEEE International Conference Intelligent Systems IS'2014*, 2015, vol. 322, pp. 769–780.
- [3] D. Kryukov, M. Agafonova, dan A. Arestova, "Comparison of Regression and Neural Network Approaches to Forecast Daily Power Consumption Kryukov," pada *IFOST-2016: Power Engineering and Renewable Energy Technologies Comparison*, 2016, no. 4, pp. 247–250.
- [4] J. Gonzalez, E. Lezmi, T. Roncalli, dan J. Xu, "Financial Applications of Gaussian Processes and Bayesian Optimization," pp. 1–42, 2019, tersedia di SSRN: <https://ssrn.com/abstract=3344332> atau <http://dx.doi.org/10.2139/ssrn.3344332>.
- [5] Y. Fu, Z. Li, H. Zhang, dan P. Xu, "Using Support Vector Machine to Predict Next Day Electricity Load of Public Buildings with Sub-metering Devices," *9th Int. Symp. Heating, Vent. Air Cond. 3rd Int. Conf. Build. Energy Environ.*, vol. 121, pp. 1016–1022, 2015.
- [6] M. Syafruddin dan L. Hakim, "Metode Regresi Linier Untuk Prediksi Kebutuhan Energi Listrik Jangka Panjang (Studi Kasus Provinsi Lampung)," *Jurnal Informatika dan Teknik Elektro*, no. 1, 2014.
- [7] O. Gamze, D. Omer F, dan Z. Selim, "Forecasting Electricity Consumption with Neural Networks dan Support Vector Regression," pada *8th International Strategic Management Conference Forecasting*, 2012, vol. 58, pp. 1576–1585.
- [8] M. T. Leung, A. Chen, dan H. Daouk, "Forecasting Exchange Rates Using General Regression Neural networks," *Comput. Oper. Res.*, vol. 27, no. 11–12, pp. 1093–1110, 2000.
- [9] Adhyani dan Subanar, "General Regression Neural Network (GRNN) Pada Peramalan Kurs Dolar dan Indeks Harga Saham Gabungan (IHSG)," *Fakta Exacta*, vol. 8, pp. 137–144, 2015.
- [10] R. . Caraka, H. Yasin, dan P. A, "Pemodelan General Regression Neural Network (Grnn) Pada Data Return Indeks Harga Saham Euro 50," *Gaussian*, vol. 4, pp. 181–192, 2015.
- [11] D. Niu, H. Wang, H. Chen, dan Y. Liang, "The General Regression Neural Network Based on the Fruit Fly Optimization Algorithm and the Data Inconsistency Rate for Transmission Line Icing Prediction," *Energies*, vol. 10, no. 2066, 2017.
- [12] N. K. Singh, A. K. Singh, dan P. Kumar, "PSO optimized radial basis function neural network based electric load forecasting model," *2014 Australas. Univ. Power Eng. Conf. AUPEC 2014 - Proc.*, no. October, pp. 1–6, 2014.
- [13] O. C. Ozerdem, E. O. Olaniyi, dan O. K. Oyedotun, "Short term load forecasting using particle swarm optimization neural network," *Procedia Comput. Sci.*, vol. 120, pp. 382–393, 2017.
- [14] D. F. Specht, "A General Regression Neural Network," *IEE Trans*, vol. 2, pp. 568–576, 1991.
- [15] W. Pan, "Knowledge-Based Systems A new Fruit Fly Optimization Algorithm : Taking the financial distress model as an example," *Knowledge-Based Syst.*, vol. 26, pp. 69–74, 2012.
- [16] B. Li, H. Guo, S. Zhao, H. Su, dan C. Wang, "Annual Electric Load Forecasting by a Least Squares Support Vector Machine with a Fruit Fly Optimization Algorithm," *Energies*, vol. 5, pp. 4430–4445, 2012.
- [17] D. F. Specht, "General Regression Neural Network ( GRNN )," pada *General Regression Neural Network ( GRNN )*, 1991, pp. 42–60.