

Prediksi Kebutuhan Permintaan Energi Listrik Menggunakan Neural Network Berbasiskan Algoritma Genetika

Oman Somantri¹, Vincent Suhartono², Catur Supriyanto³, Mohammad Khambali⁴

¹Jurusan Teknik Informatika, Politeknik Harapan Bersama Tegal

^{2,3}Jurusan Magister Teknik Informatika, Universitas Dian Nuswantoro Semarang

⁴Jurusan Teknik Listrik, Politeknik Negeri Semarang

Jl. Mataram No.03 Pesurungan Lor, Kota Tegal, Indonesia¹

Jl. Nakula I No. 5-11, Semarang, Indonesia^{2,3}

Jl. Prof. H. Soedarto, SH, Tembalang Semarang, Indonesia⁴

¹oman_mantri@yahoo.com, ²vincent.suhartono@dsn.dinus.ac.id, ³catur.dinus@gmail.com,

⁴mc.chambali.poltek@gmail.com

Abstract—To predict the demand of electrical energy needs is not easy, accurate prediction is necessary for policy holders in making a decision related to the management of electrical energy. In predicting the need of electrical energy demand in short term is used Neural Network as a model that applied. There are several parameters to implement Neural Network that must be determined as learning rate and momentum, the problem is the lack of standard guidelines in determining the parameters that will be used, therefore in this method used the experimental method. So that we need a method that can resolve the problem, then that the parameters obtained become more optimal. Solutions that can be applied is to apply the genetic algorithm (GA) on Neural Networks, in order to optimize the value of learning rate and momentum parameters. The results are the application of optimization techniques with Genetic Algorithm can facilitate the search for optimal parameter values and increase the value of the accuracy of the Neural Network algorithm, thus the model obtained can be used for decision-makers in determining the decision making to determine the short-term planning related electrical energy management issues, especially the needs of electric energy demand.

Keywords- *Electrical energy demand, Neural network, parameters, Genetic Algorithm (GA)*

Abstrak—Untuk memprediksi permintaan kebutuhan energi listrik sangatlah tidak mudah, prediksi yang akurat sangat dibutuhkan bagi para pemegang kebijakan dalam mengambil sebuah keputusan terkait dengan pengelolaan energi listrik. Dalam memprediksi kebutuhan permintaan energi listrik dalam jangka pendek ini digunakan *Neural Network* sebagai model yang diterapkan. Untuk mengimplementasikan *Neural Network* ada beberapa parameter yang harus kita tentukan seperti *learning rate* dan *momentum*, permasalahannya adalah tidak adanya pedoman baku dalam menentukan parameter yang akan digunakan pada metode ini sehingga yang dipakai adalah metode eksperimen. Untuk itu diperlukan metode yang dapat menyelesaikan permasalahan tersebut, sehingga parameter yang didapatkan dapat menjadi lebih optimal. Solusi yang dapat diterapkan adalah dengan menerapkan Algoritma genetika (GA) pada *Neural Network*, untuk dapat mengoptimalkan nilai parameter *learning rate* dan *momentum*. Hasil yang didapatkan adalah ternyata penerapan teknik optimasi dengan Algoritma Genetika dapat mempermudah dalam mencari nilai parameter secara

optimal dan dapat meningkatkan nilai akurasi pada algoritma *Neural Network*, dengan demikian model yang didapatkan dapat digunakan bagi para pengambil kebijakan dalam menentukan pengambilan keputusan untuk menentukan perencanaan jangka pendek terkait dengan masalah pengelolaan energi listrik khususnya kebutuhan permintaan energi listrik.

Kata Kunci- *Energi listrik, Neural network, parameter, algoritma genetika.*

I. PENDAHULUAN

Energi listrik dewasa ini sudah menjadi kebutuhan pokok bagi setiap orang, hal ini memberikan sebuah kewajiban apabila energi listrik menjadi salah satu masalah pokok banyak orang yang membicarakannya [1]. Energi listrik merupakan salah satu pendorong dari kekuatan berkembangnya perekonomian [2]. Konsumsi energi sekarang ini terus meningkat selama beberapa dekade terakhir di seluruh dunia karena meningkatnya jumlah penduduk dan pembangunan ekonomi. Energi dianggap sebagai faktor penting dalam pembangunan ekonomi dan sosial suatu negara dan akibatnya berimbas kepada perekonomian rakyat. Energi merupakan bagian penting dari kehidupan sehari-hari manusia dan sangat dibutuhkan dalam hampir setiap kegiatan [3].

Prediksi kebutuhan permintaan listrik merupakan faktor penting yang mengarah kepada keberhasilan perencanaan efisiensi sebuah penggunaan konsumsi energi. Upaya dalam membuat pemodelan permintaan energi merupakan komponen penting untuk perencanaan energi, merumuskan strategi, dan merekomendasikan kebijakan-kebijakan energy [4]. Peramalan konsumsi energi listrik memainkan peranan yang sangat penting dalam perencanaan peningkatan kinerja energi, penghematan energi dan pengurangan limbah energi terhadap lingkungan, selain itu mempunyai peranan penting dalam pengambilan sebuah keputusan dan perencanaan di masa depan salah satu sumber informasinya adalah mengandalkan hasil dari akurasi peramalan tersebut [5]. Sebuah analisis peramalan permintaan energi listrik sangatlah diperlukan disertai dengan teknik peramalan yang tepat tentunya akan bisa memberikan perkiraan yang akurat dalam memprediksi

jumlah konsumsi energi listrik, sehingga para pengambil kebijakan dalam hal ini pemerintah bisa membuat sebuah kebijakan terkait dengan permintaan energi listrik.

Terdapat beberapa metode yang populer yang sering digunakan untuk peramalan konsumsi energi, diantaranya *engineering method*, *statistical method* dan metode kecerdasan buatan. Diantara metode ini yang paling banyak digunakan adalah metode kecerdasan buatan atau *Artificial Intelligence* (AI) yaitu *Artificial Neural Network* (ANN) dan *Support Vector Machine* (SVM) [6][7]. Penelitian prediksi kebutuhan dan permintaan energi listrik sebelumnya sudah pernah dilakukan, Bilgili, dkk (2012) menerapkan model *Neural Network* (NN), *regresi linier* (LR) dan *regresi nonlinear* (NLR) untuk memperkirakan pemakaian konsumsi listrik pada perumahan dan sektor industri di Turki [8]. Penelitian berikutnya A.Kheirkhah, dkk (2013) menggunakan pendekatan metode *Artificial Neural Network* (ANN), *Principal Component Analysis* (PCA), *Data Envelopment Analysis* (DEA) dan ANOVA untuk memperkirakan dan memprediksi permintaan energi listrik untuk perubahan setiap musim dan konsumsi listrik bulanan [9]. Kandananond (2011) menggunakan model *Moving Average* (ARIMA), *Artificial Neural Network* (ANN) dan *Multiple linear regression* (MLR) untuk meneliti perkiraan kebutuhan listrik di Negara Thailand. Hasilnya memperlihatkan nilai *Mean Absolute Percentage Error* (MAPE) dari masing – masing model yaitu ANN sebesar 0,996%, ARIMA sebesar 2.80981%, dan MLR 3,2604527%. Berdasarkan hasil penelitian menunjukkan bahwa ANN lebih baik daripada ARIMA dan MLR [10].

Penelitian kemudian dilakukan untuk optimalisasi sebagai peningkatan akurasi, seperti yang dilakukan Liu, dkk (2012) menggunakan *Genetic algorithm* (GA) dan *Back Propagation* (BP) *Neural Network* untuk prediksi pinjaman pemakaian energi listrik pada industry [11] dan Ning An, dkk (2013) meneliti mengenai peramalan kebutuhan energi listrik, dalam penelitian ini diperkenalkan sebuah pendekatan model baru yaitu MFES merupakan kombinasi antara dua model yaitu *Feedforward Neural Network* (FNN) dan *Empirical Mode Decomposition* (EMD) yang berbasis *Signal Filtering* serta *Seasonal adjustment*, disimpulkan bahwa dengan model MFES yang diusulkan dapat meningkatkan akurasi peramalan permintaan listrik [12].

Neural Network mempunyai kelebihan yaitu mampu untuk dapat melakukan pembelajaran berdasarkan data yang digunakan untuk pelatihan, dapat melakukan *self organization* atau melakukan representasi dari informasi yang diterimanya, serta memiliki *real time operation* dengan kata lain *Artificial Neural Network* dapat melakukan perhitungan secara parallel serta memiliki *fault* toleran yang tinggi [13]. Disamping itu *Artificial Neural Network* memiliki beberapa kelebihan lainnya diantaranya adalah kemampuannya dalam melakukan pemodelan untuk pengenalan pola [14]. Salah satu teknik populer pada metode *neural network* adalah algoritma *backpropagation* yang banyak digunakan untuk memecahkan banyak permasalahan yang ada dengan membangun model terlatih yang menunjukkan kinerja

yang baik dalam beberapa masalah yang sifatnya non-linear.

Selain memiliki kelebihan *backpropagation* juga mempunyai beberapa kelemahan, diantaranya: (1) algoritma *backpropagation* bisa terjebak dalam masalah lokal minimum, hal ini dapat menyebabkan kegagalan untuk mencari solusi yang optimal dalam pemilihan fitur pada bobot atribut yang digunakan, (2) algoritma *backpropagation* memiliki kecepatan konvergen yang terlalu lambat yang pada akhirnya algoritma *backpropagation* sangat tergantung pada parameter awal seperti jumlah masukan, node tersembunyi, *output*, *learning rate* dan bobot koneksi dalam jaringan [15]. Masalah lainnya adalah mempunyai kelemahan pada perlunya data *training* yang besar dan optimasi yang digunakan kurang efisien. Dalam mengimplementasikan *Neural Network* ada beberapa parameter yang harus kita tentukan dan selama ini tidak ada ketentuan yang baku dalam menentukan parameter *Neural Network* sehingga metode yang dipakai adalah metode eksperimen [16]. Untuk itu diperlukan metode yang dapat menyelesaikan permasalahan tersebut, sehingga pengimplementasian *Neural Network* dapat lebih efisien [17].

Algoritma Genetika merupakan salah satu metode optimasi yang handal sehingga dapat digunakan untuk menentukan nilai parameter kontrol yang optimal untuk suatu proses tertentu [16]. Algoritma Genetika memiliki beberapa kelebihan diantaranya adalah dapat digunakan untuk variabel diskrit maupun kontinyu, dapat digunakan untuk variabel yang besar, hasil akhir berupa beberapa *variable* yang optimum, tidak hanya satu penyelesaian saja, optimasi dilakukan dengan mengkodekan *variable* dan dapat digunakan pada data numerik, data eksperimental, atau fungsi analitik [18].

Pada penelitian yang dilakukan ini untuk dapat meningkatkan tingkat akurasi yang dihasilkan oleh *neural network* dalam memprediksi permintaan energi listrik maka algoritma genetika diusulkan menjadi solusi, yaitu digunakan untuk mengoptimalkan nilai parameter *neural network* diantaranya nilai *learning rate* dan *momentum* sehingga dapat memperoleh nilai parameter yang lebih optimal sehingga dapat meningkatkan tingkat akurasi prediksi permintaan energi listrik.

II. TINJAUAN PUSTAKA

A. Algoritma Backpropagation

Backpropagation ditemukan pertama kalinya oleh Paul W tahun 1974, kemudian dikembangkan oleh Rumelhart dan McClelland diimplementasikan kedalam *neural network*. Metode *backpropagation* pada awalnya dirancang untuk *neural network feedforward*, tetapi pada perkembangannya, metode ini diadaptasi untuk pembelajaran pada model *neural network* lainnya [19]. Sebagai algoritma yang termasuk kedalam metode pelatihan yang terawasi, *backpropagation* bekerja dengan cara meminimalkan error pada output yang dihasilkan oleh model jaringannya.

Backpropagation neural network banyak diaplikasikan secara luas dan pengaplikasiannya telah berhasil di

berbagai bidang, seperti finansial, pengenalan pola tulisan, pengenalan pola suara dan sistem kendali serta pengolah citra medika. *Backpropagation* berhasil menjadi salah satu metode komputasi yang handal. Konsep dari algoritma backpropagation yaitu ketika hasil keluaran output memberikan nilai hasil yang salah, maka bobot (weight) dalam jaringan akan dikoreksi agar galat yang dihasilkan lebih kecil sehingga respon jaringan diharapkan akan mendekati nilai yang benar. *Backpropagation* mempunyai kemampuan untuk dapat memperbaiki bobot pada lapisan tersembunyi atau hidden layer [20].

B. Algoritma Genetika (GA)

Genetic Algorithm (GA) adalah sebuah algoritma untuk optimasi yang didasarkan prinsip proses genetika dan seleksi alam [21]. Algoritma genetika ini merupakan sebuah metode pencarian yang disesuaikan dengan sebuah proses genetik dari organisme biologi yang berdasar pada teori evolusi [22]. Konsep dari algoritma genetika adalah terinspirasi dari sebuah mekanisme seleksi alam, dimana individu yang lebih kuat berkemungkinan akan menjadi pemenang dalam lingkungannya, solusi yang optimal dapat diperoleh dan diwakilkan dari pemenang akhir dari proses genetika tau sering juga disebut dengan *fitness*. Solusi yang diperoleh pada algoritma genetika diterapkan pada sebuah populasi individu yang mewakili dari solusi masing-masing individu yang mewakili dari solusi yang mungkin atau disebut juga dengan nama *kromosom*.

Algoritma genetika dijadikan sebagai alternatif dalam optimalisasi bagi penentuan nilai parameter yaitu dengan cara meniru sebuah proses reproduksi genetik, pembentukan kromosom baru serta seleksi alami seperti halnya yang terjadi pada makhluk hidup [23].

C. Pengujian Error Prediksi dan Akurasi Kebenaran

Untuk menguji seberapa dekat dari perkiraan dengan nilai aktual, langkah-langkah umum memperkirakan kesalahan maka digunakan akar kesalahan kuadrat rata-rata atau *Root Mean Squared Error* (RMSE) dengan menggunakan persamaan:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_t - O_t)^2}{n}} \quad (1)$$

dimana :

n = jumlah data,

Y_t = nilai aktual pada periode waktu t .

O_t = nilai ramalan untuk periode waktu t .

$(Y_t - O_t)$ = *error* ramalan pada periode waktu t .

III. METODOLOGI PENELITIAN

A. Data Penelitian

Dataset yang digunakan pada penelitian ini adalah data *times series* permintaan konsumsi energi listrik yang diambil tahun 2013 dari Australian Energy Market Operator (AEMO) www.aemo.au. Dataset permintaan energi listrik dari AEMO yang diambil adalah permintaan kebutuhan energi listrik di Negara Australia bagian wilayah Victoria dalam kurun waktu selama tiga bulan

pada tahun 2013 yaitu mulai tanggal 1 Oktober 2013 pada jam 00:00:00 AM sampai dengan tanggal 31 Desember 2013 jam 11:30:00 PM yang terdiri dari 5 (lima) atribut data yaitu *REGION* (wilayah), *SETTLEMENTDATE* (tanggal dan waktu), *TOTALDEMAND* (permintaan listrik) dan *RRP* (harga listrik), *PERIODTYPE* (keterangan) dengan jumlah data 4416 *record* data .

Tabel 1. *Dataset real* permintaan energi listrik daerah Victoria Australia

Region	Settlement Date	Total Demand	RRP	Period Type
VIC1	10/1/2013 0:00	5282.28	50.09	TRADE
VIC1	10/1/2013 0:30	4874.85	47.5	TRADE
VIC1	10/1/2013 1:00	4431.29	45.81	TRADE
VIC1	10/1/2013 1:30	4285.57	43.73	TRADE
VIC1	10/1/2013 2:00	4183.53	43.44	TRADE
VIC1	10/1/2013 2:30	4013.24	39.43	TRADE
VIC1	10/1/2013 3:00	3918.24	39.27	TRADE
VIC1	10/1/2013 3:30	3823.37	37.18	TRADE
VIC1	10/1/2013 4:00	3798.98	38.84	TRADE
...
...
VIC1	12/31/2013 22:30	4482.53	43.74	TRADE
VIC1	12/31/2013 23:00	4515.98	43.34	TRADE
VIC1	12/31/2013 23:30	4890.53	44.33	TRADE

B. Pengolahan awal (preprocessing)

Sebelum dilakukan pengolahan data sesuai dengan dataset yang akan digunakan, maka terlebih dahulu melakukan beberapa tahapan awal yaitu melakukan *preprocessing* data. Pada tahapan ini dilakukan beberapa hal, diantaranya:

1) Melakukan pemilihan variabel:

Untuk mempermudah penggunaan data karena yang akan digunakan adalah hanya beberapa variable saja yang terkait dengan penelitian yaitu permintaan kebutuhan energi listrik, maka pada dataset dipilih *variable* yang sesuai untuk digunakan sebagai inputan. Karena *dataset real* yang ada terdapat 5 variabel maka diambil hanya 2 yaitu *SETTLEMENTDATE* dan *TOTALDEMAND* saja karena yang akan kita olah datanya adalah prediksi permintaan konsumsi energi listrik tetapi jumlah data masih tetap 4416 *record* data.

2) Penentuan data input dan output:

Dikarenakan data yang didapatkan setelah pemilihan *variable* menjadi *univariat*, maka *variable* tersebut kemudian dijadikan *multivariate* dengan menggunakan konsep *windowing* pada tools yang dipakai. Setelah dilakukan eksperimen terhadap jumlah atribut yang digunakan dari variabel *TOTALDEMAND*, maka didapatkan jumlah atribut terbaik yang digunakan untuk *input* data sebanyak 10 inputan diantaranya *TOTALDEMAND-0*, *TOTALDEMAND-1*, *TOTALDEMAND-2*, *TOTALDEMAND-3*, *TOTALDEMAND-4*, *TOTALDEMAND-5*, *TOTALDEMAND-6*, *TOTALDEMAND-7*, *TOTALDEMAND-8* dan *TOTALDEMAND-9*, sedangkan *output* data hanya 1 (satu) keluaran yaitu ditandai dengan

satu “label” sehingga jumlah data menjadi 4406 record. untuk atribut *SETTLEMENTDATE* pada dataset dijadikan sebagai atribut yang mempunyai role “id” seperti ditunjukkan pada tabel 2.

Tabel 2. Atribut untuk input dan output data

ExampleSet (4406 examples, 2 special attributes, 10 regular attributes)			
Role	Name	Type	Statistics
label	label	numeric	avg = 5209.727 +/- 742.422
id	SETTLEMENTDATE	date_time	length = 92 days
regular	TOTALDEMAND-9	numeric	avg = 5208.768 +/- 743.701
regular	TOTALDEMAND-8	numeric	avg = 5208.674 +/- 743.718
regular	TOTALDEMAND-7	numeric	avg = 5208.647 +/- 743.732
regular	TOTALDEMAND-6	numeric	avg = 5208.706 +/- 743.681
regular	TOTALDEMAND-5	numeric	avg = 5208.812 +/- 743.583
regular	TOTALDEMAND-4	numeric	avg = 5208.928 +/- 743.463
regular	TOTALDEMAND-3	numeric	avg = 5209.056 +/- 743.305
regular	TOTALDEMAND-2	numeric	avg = 5209.172 +/- 743.143
regular	TOTALDEMAND-1	numeric	avg = 5209.322 +/- 742.930
regular	TOTALDEMAND-0	numeric	avg = 5209.485 +/- 742.700

3) Penentuan data training dan testing

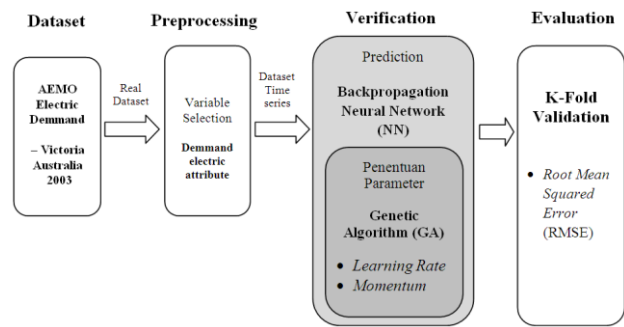
Data training dalam penelitian ini diambil dari permintaan kebutuhan energi listrik di Negara Australia bagian wilayah Victoria dalam kurun waktu selama 3 (tiga) bulan pada tahun 2013 yaitu mulai tanggal 1 Oktober 2013 jam 00:00:00 AM s.d 31 Desember 2013 jam 11:30:00 PM. Untuk menguji model yang telah didapatkan, maka nantinya hasil pelatihan akan digunakan untuk memprediksi permintaan energi listrik pada durasi output satu hari yaitu tanggal 1 Januari 2014 pada antara jam 00:00:00 AM s,d jam 11:30:00 PM.

C. Metode Yang Diusulkan

Metode yang diusulkan adalah penggunaan *Neural Network* (NN) *Backpropagation* untuk prediksi permintaan energi listrik. Untuk meningkatkan tingkat akurasi prediksi permintaan energi listrik maka menerapkan algoritma genetika (GA). Penerapan *Genetic Algorithm* (GA) pada penelitian ini adalah digunakan untuk penentuan dalam pencarian nilai parameter yaitu *learning rate* dan *momentum* pada neural network sehingga mendapatkan nilai parameter yang lebih optimal sehingga dapat meningkatkan tingkat kaurasi prediksi pada model yang akan diterapkan

D. Eksperimen dan Pengujian

Untuk eksperimen dan pengujian pada metode yang diusulkan, menggunakan tools Rapid Miner 5. Data sudah dipersiapkan sebelumnya kemudian dimasukan kedalam model yang sudah dibuat dan dimodifikasi sedemikian rupa untuk mendapatkan hasil yang diinginkan. Data akan diuji akurasinya dengan menggunakan *K folds x-validations*. Gambaran metode yang diusulkan seperti pada gambar 1:



Gambar 1. Metode yang diusulkan


E. Evaluasi dan Validasi

Forecasting Performance Accuration digunakan untuk melihat tingkat akurasi yang dihasilkan dari *proposed method*, pada penelitian ini yaitu dengan menggunakan metode *K-folds validations* untuk mencari nilai *Root Mean Squared Error* (RMSE) yang kemudian hasil dari akurasi tersebut dievaluasi dengan cara membandingkan tingkat akurasi yang dihasilkan oleh model *neural network* yang menggunakan algoritma genetika dengan model *neural network* tanpa algoritma genetika.

IV. HASIL DAN PEMBAHASAN

A. Model Neural Network yang dihasilkan

Untuk mendapatkan model yang sesuai dalam penelitian ini, arsitektur *neural network* yang didapatkan adalah seperti pada gambar 2 dibawah ini:



Gambar 2. Arsitektur model neural network yang dihasilkan

Sesuai dengan gambar 4 diatas, jumlah *neuron* untuk input data adalah berjumlah 10 *neuron*, dengan menggunakan 1 lapisan *hidden layer* dengan jumlah *neuron* sebanyak 7 *neuron* dan 1 *neuron* sebagai output.

Dengan menggunakan NN sebagai model, maka parameter terbaik yang digunakan untuk memprediksi permintaan energi listrik seperti pada tabel 3 dibawah ini:

Tabel 3. Parameter Model NN

Parameter	Value
Input (neuron)	10
Output (neuron)	1
Training Cycles	500
Hidden Layer / neurom	1 / 7 neuron
Learning rate	0.2
Momentum	0.2
RMSE	97.174

Dengan menggunakan model arsitektur seperti pada tabel diatas, menghasilkan sebuah nilai prediksi RMSE (*Root Mean Squared Error*) sebesar 97.174. Adapun kombinasi nilai RMSE berdasarkan eksperimen seperti pada tabel 4.

Tabel 4. Kombinasi RMSE Eksperimen Model NN

training cycles	momentum	learning rate	RMSE
500	0.2	0.1	102.443
500	0.2	0.2	97.174
500	0.2	0.3	99.121
500	0.2	0.4	104.999
500	0.2	0.5	110.639
500	0.2	0.6	132.108
500	0.2	0.7	143.755
500	0.2	0.8	174.504
500	0.2	0.9	194.039

B. Model NN dan GA yang dihasilkan

Setelah nilai tersebut didapatkan kemudian dilakukan eksperimen dengan menerapkan algoritma genetika. Nilai parameter untuk GA seperti pada tabel 5 dibawah ini:

Tabel 5. Penentuan parameter Genetic Algorithm (GA)

Parameter	Value
Max generations	50
Population size	5
Mutation type	Gaussian_mutation
Selection type	Roulette_wheel
Crossover prob	0.9
RMSE	94.549

Pada tabel diatas untuk mengoptimalisasi nilai parameter pada *Neural Network* digunakan pengaturan parameter pada GA dimana *Max generations* sebanyak maksimal 50, *Population size* sebanyak 5, *Mutation type* yang digunakan adalah *Gaussian_mutation* dan *Selection type* menggunakan model *Roulette wheel* serta *Crossover prob* adalah 0,9 dan menghasilkan nilai RMSE = 94.549.

C. Evaluasi Model

Berdasarkan dari analisa pengujian antara model *neural network* dengan *neural network* berbasis *Genetic Algorithm* maka dapat dirangkumkan hasilnya pada tabel 6 berikut:

Tabel 6. Hasil Analisa dan Komparasi NN dengan NN + GA

Parameter	Neural Network (NN)	Neural Network (NN) + Genetic Algorithm (GA)
Learning rate	0.2	0.18347049067245383
Momentum	0.2	0.3717224921578156
RMSE	97.174	94.549

Berdasarkan hasil analisa dalam eksperimen yang telah dilakukan terlihat bahwa dengan adanya optimalisasi penentuan parameter *Neural Network* (NN) dengan menggunakan algoritma genetika (GA) menjadikan nilai prediksi RMSE menjadi lebih baik, yaitu adanya penurunan nilai RMSE (*Root Mean Squared Error*) sebesar 2.625 dari 97.174 menjadi 94.549. Dengan demikian dengan optimalisasi algoritma genetika terhadap *neural network* terjadi sebuah peningkatan prediksi yaitu dengan adanya penurunan nilai RMSE (*Root Mean Squared Error*), sehingga nilai akurasi *Neural Network* dengan menggunakan algoritma Genetika lebih baik dibandingkan dengan NN tanpa menggunakan GA.

Sebagai pengujian, untuk memperoleh presentasi kebenaran (*accuracy*) dari hasil pelatihan, dilakukan pengujian dengan *data real* yang diperoleh untuk tanggal 1 Januari 2014 jam 04:30:00 AM s,d jam 11:30:00 PM atau 23.30.00 menggunakan rumus:


$$Accuracy = 100\% - \left(\frac{|DataActual - Nilai\ Prediksi|}{NilaiActual} \times 100\% \right) \quad (2)$$

Maka hasilnya didapatkan seperti pada tabel 7:

Tabel 7. Perbandingan data actual dan prediksi

Setlemen Date	Prediction	Actual	Error	Accuracy (%)
Jan 01 04:30:00	3655.45	3591.05	64.40	98.21
Jan 01 05:00:00	3656.93	3606.73	50.20	98.61
Jan 01 05:30:00	3646.49	3616.21	30.28	99.16
Jan 01 06:00:00	3664.39	3641.2	23.19	99.36
Jan 01 06:30:00	3873.44	3759.78	113.66	96.98
Jan 01 07:00:00	3918.41	3850.59	67.82	98.24
Jan 01 07:30:00	3864.81	3883.11	18.30	99.53
Jan 01 08:00:00	4123.70	4037.1	86.60	97.85
Jan 01 08:30:00	4058.88	4075.31	16.43	99.60
Jan 01 09:00:00	4200.11	4163.49	36.62	99.12
Jan 01 09:30:00	4201.86	4222.86	21.00	99.50
Jan 01 10:00:00	4305.67	4299.33	6.34	99.85
Jan 01 10:30:00	4282.33	4335.77	53.44	98.77
Jan 01 11:00:00	4392.63	4394.16	1.53	99.97
Jan 01 11:30:00	4521.69	4495.13	26.56	99.41
Jan 01 12:00:00	4455.85	4497.75	41.90	99.07
...
...
Jan 01 23:00:00	4459.10	4366.34	92.76	97.88
Jan 01 23:30:00	4958.03	4782.16	175.87	96.32
Rata - Rata				98.78

Berdasarkan tabel 7 rata-rata akurasi prediksi yang dihasilkan adalah 98.78%, dan secara grafik dapat diperlihatkan seperti pada gambar 3.



Gambar 3. Grafik akurasi data actual dan data prediksi

V. KESIMPULAN DAN SARAN

Dari penelitian yang dilakukan, penentuan nilai parameter yang telah dioptimasi menggunakan Algoritma Genetika terbukti mampu meningkatkan akurasi prediksi pada kebutuhan permintaan energi listrik. Model yang dibentuk oleh *neural network* berbasis algoritma Genetika menghasilkan akurasi yang lebih baik dibandingkan dengan *neural network* dengan tanpa dioptimasi. Hasil optimasi ini sangat penting dalam penentuan nilai parameter yang paling optimal, sehingga menghasilkan tingkat akurasi yang lebih baik. Dapat disimpulkan bahwa penerapan teknik optimasi dengan algoritma genetika dapat mempermudah dalam mencari nilai parameter optimal yang dapat meningkatkan nilai akurasi pada algoritma *Neural Network* sehingga dapat digunakan bagi para pengambil kebijakan untuk dapat menentukan pengambilan keputusan dalam menentukan perencanaan jangka pendek terkait dengan masalah pengelolaan energi listrik khususnya kebutuhan permintaan energi listrik.

Walaupun model algoritma *neural network* yang digunakan sudah memberikan hasil yang lebih baik, namun ada beberapa hal yang dapat ditambahkan untuk penelitian selanjutnya:

- Adanya penelitian lebih lanjut dengan model yang telah diusulkan dengan menggunakan *dataset* dan studi kasus yang berbeda, pada penelitian ini karakteristik permintaan beban pada hari kerja dan hari libur tidak dibedakan. Kedepan perlu adanya penelitian yang sejenis tetapi *dataset* yang digunakan lebih dititik beratkan kepada pembagian antara hari kerja dan hari libur sehingga perbedaan permintaan energi listrik lebih terlihat.
- Dari model yang terbentuk dapat diimplementasikan menjadi sebuah aplikasi yang dapat digunakan para pengambil kebijakan terkait dengan pengelolaan energi listrik.

REFERENSI

- [1] R.Menaa, F. Rodríguez, M. Castilla & M.R. Arahal " A prediction model based on neural networks for the energy consumption of a bioclimatic building ," *Energy and Buildings* 8, 2014 , pp. 142–155
- [2] Ping Zhang & Hui Wang, "Fuzzy Wavelet Neural Networks for City Electric Energy Consumption Forecasting", *2012 International Conference on Future Electrical Power and Energy Systems, Energy Procedia* 17, (2012), 1332 – 1338
- [3] L. Ekonomou, "Greek long-term energy consumption prediction using artificial neural networks", *Energy* 35 ,(2010), 512–517
- [4] A.S.Ahmad, M.Y.Hassan, M.P.Abdullah, H.A.Rahman, F.Hussin, H.Abdullah & R.Saidur, "A review on applications of ANN and SVM for building electrical energy consumption forecasting", *Renewable and Sustainable Energy Reviews* 33, (2014), 102-
- [5] Zebulum Ricardo S, Vellasco Marley, Guedes Karla & Pacheco Marco Aurélio. "Short term load forecasting using neural nets". In : Mira J, Sandoval F, editors. *From natural to artificial neural computation*. Berlin Heidelberg : Springer; 1995, p.1001–8.109
- [6] Lee Yi-Shian,TongL-I. "Forecasting timeseries using a methodology based on autoregressive integrated moving average and genetic programming." *Knowl- Based Syst* 2011;24(1) : 66–72.
- [7] Mohammed El-Telbany & Fawwaz El-Karmi, "Short-term forecasting of Jordanian electricity demand using particle swarm optimization", *Electric Power Systems Research* 78 , 2008, 425–433
- [8] A. Kheirkhah, A. Azadeh , M. Saberi , A. Azaron & H. Shakouri, "Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis " , *Computers & Industrial Engineering* 64, (2013), 425–441
- [9] Fausett, L. (1994). *Fundamental Of Neural Network Architecture, Algorithms, And Applications*. New Jersey: Prentice Hall.
- [10] Karin Kandananond, "Forecasting Electricity Demand in Thailand with an Artificial Neural Network Approach", *Energies*, 2011, 4, 1246-1257
- [11] Liu Ke, Guo Wenyan, Shen Xiaoliu & Tan Zhongfu, "Research on the Forecast Model of Electricity Power Industry Loan Based on GA-BP Neural Network", *Energy Procedia* 14, (2011), 1918–1924
- [12] Ning An dkk, "Using multi-output feedforward neural network with empirical mode decomposition based signal filtering for electricity demand forecasting". *Energy* 49, (2013), 279-288
- [13] Gupta, Madan, M. , Jin, L., & Homma, N. (2003). *Static And Dynamic Neural Networks From Fundamentals to Advanced Theory*. A John Wiley and Sons, Ltd.
- [14] Park, T. S., Lee, J. H., & Choi, B. (2009)."Optimization for Artificial Neural Network with Adaptive inertial weight of particle swarm optimization. *Cognitive Informatics", IEEE International Conference* , 481-485.
- [15] Xiao, & Shao, Q. (2011),"Based on two Swarm Optimized algorithm of neural network to prediction the switch's traffic of coal". ISCCS '11 Proceeding of the 2011 International Symposium on Computer Science and Society , 299-302.
- [16] Wu, G. (2009),"Research on Parameter Optimization of Neural Network". *International Journal of Hybrid Information Technology Vol. 2, No. 1*, January, 2009, 81.
- [17] Zhang, Q., & Wang, C. (2008). "Using Genetic Algorithm to optimize Artificial Neural Network :A Case Study on Earthquake Prediction". *2008 Second International Conference on Genetic and Evolutionary Computing*, 128-131
- [18] Haupt, R. L. ., & Haupt, S. E. (2004). *Practical Genetic Algorithms* (Second Edi.). New Jersey: A John Wiley and Sons, Ltd.
- [19] Astuti, E. D. (2009). *Pengantar Jaringan Saraf Tiruan*. Wonosobo: Star Publishing -
- [20] Purnomo, M. H., & Kurniawan, A. (2006). *Supervised Neural Network*. Surabaya: Garaha Ilmu.
- [21] Shukla, A., Tiwari, R., & Kala, R. (2010). *Real Life Application of Soft Computing*. CRC Press.
- [22] Melanie, M. (1999). *An Introduction to Genetic Algorithms* (Five Editi.). London: MI Press.
- [23] Weise, T. (2009). *Global Optimization Algorithms – Theory and Application* (Second Edi.).it-weise.de (self-published).