

Algoritme Genetika untuk Peningkatan Prediksi Kebutuhan Permintaan Energi Listrik

Oman Somantri¹, Catur Supriyanto²

Abstract— Predicting the demand of electrical energy with a high degree of accuracy is expected. Application of an appropriate model using exact method will greatly affect the level of accuracy result. Neural Network (NN) and Support Vector Machine (SVM) models are used to predict the needs of electricity demand. Those models have weaknesses. Both are still difficult in determining the value of parameters used, thus, affecting the level of accuracy. Genetic Algorithm (GA) is proposed as a method to optimize the value of NN and SVM parameters in predicting the demand of electrical energy. The result shows that the NN and GA models have a better accuracy than the SVM and GA.

Intisari— Memprediksi kebutuhan permintaan energi listrik dengan tingkat akurasi yang tinggi sangatlah diharapkan. Penerapan model yang sesuai dengan metode yang tepat akan sangat berpengaruh terhadap tingkat akurasi yang dihasilkan. Model *Neural Network* (NN) dan *Support Vector Machine* (SVM) digunakan untuk memprediksi kebutuhan permintaan listrik. Model yang digunakan mempunyai kekurangan yaitu kedua model tersebut masih sulit dalam menentukan nilai parameter yang digunakan, sehingga berpengaruh terhadap tingkat akurasi yang dihasilkan. Algoritma Genetika (GA) diusulkan sebagai metode untuk mengoptimasi nilai parameter NN dan SVM dalam memprediksi permintaan energi listrik. Hasil menunjukkan bahwa model NN dan GA memiliki tingkat akurasi yang lebih baik dibandingkan dengan SVM dan GA.

Kata Kunci— listrik, *Neural Network*, *Support Vector Machine*, Algoritma Genetika.

I. PENDAHULUAN

Salah satu pendorong kekuatan perekonomian suatu negara dan merupakan masalah kebutuhan pokok bagi setiap orang adalah energi listrik [1],[2]. Energi listrik merupakan kebutuhan sehari-hari setiap orang dalam melakukan setiap kegiatan, sehingga konsumsi energi listrik terus meningkat dan berimbas kepada pembangunan ekonomi dan sosial suatu Negara [3].

Salah satu faktor penting yang memengaruhi keberhasilan perencanaan konsumsi energi adalah perkiraan kebutuhan listrik. Peranan kebijakan dalam membuat sebuah model untuk memprediksi permintaan listrik dapat dijadikan sebagai tolok ukur dalam perencanaan energi, merumuskan strategi

serta merekomendasikan kebijakan-kebijakan terkait dengan energi [4]. Selain itu, peramalan konsumsi energi listrik memainkan peranan penting dalam sebuah peningkatan kinerja energi, pengurangan limbah energi terhadap lingkungan, serta dijadikan sebagai pengambilan keputusan[5]. Kebijakan pemerintah dalam mengambil keputusan tentunya harus tepat dan tidak merugikan semua pihak. Dengan adanya pola untuk memprediksi kebutuhan permintaan energi listrik dengan menggunakan model yang tepat diharapkan akan menjadi salah satu pendukung keputusan dalam merencanakan segala aspek terkait dengan energi listrik. Terdapat beberapa metode populer yang sering digunakan untuk peramalan konsumsi energi, di antaranya adalah *Artificial Intelligence* (AI) yaitu *Artificial Neural Network* (ANN) dan *Support Vector Machine* (SVM) [6][7].

Beberapa penelitian telah dilakukan sebelumnya dalam memprediksi permintaan kebutuhan energi listrik, di antaranya dilakukan oleh Bilgili, dkk (2012) meneliti pemakaian konsumsi listrik pada perumahan dan sektor industri di Negara Turki. Pada penelitian ini dicoba diterapkan model *Neural Network* (NN), *Regresi Linier* (LR) dan *Regresi Non Linear* (NLR) [8]. Penelitian lainnya, A. Kheirkhah, dkk (2013) menggunakan pendekatan metode ANN, *Principal Component Analysis* (PCA), *Data Envelopment Analysis* (DEA), dan ANOVA [9]. Model *Moving Average* (ARIMA), ANN dan *Multiple Linear Regression* (MLR) digunakan oleh Kandanand (2011) untuk meneliti perkiraan kebutuhan listrik di Negara Thailand dan hasil penelitiannya menunjukkan bahwa ANN lebih baik daripada ARIMA dan MLR [10].

Selain penelitian yang telah disebutkan, pengoptimalan untuk peningkatan akurasi telah dilakukan oleh Liu, dkk (2012) [11], yang mengusulkan *Genetic Algorithm* (GA) dan *Back Propagation* (BP) *Neural Network*, selain itu Ning An, dkk (2013) [12] mengusulkan model MFES yang merupakan kombinasi antara dua model yaitu *Feedforward Neural Network* (FNN) dan *Empirical Mode Decomposition* (EMD), yang berbasiskan *Signal Filtering* serta *Seasonal adjustment* untuk dapat meningkatkan akurasi peramalan permintaan listrik.

Beberapa kelebihan yang dimiliki oleh NN, diantaranya adalah mampu untuk dapat melakukan pembelajaran berdasarkan data yang digunakan untuk pelatihan serta dapat melakukan *self organization* atau melakukan representasi dari informasi yang diterimanya serta memiliki *real time operation* sehingga dapat melakukan perhitungan paralel dan memiliki *fault toleran* yang tinggi [13]. Selain itu NN dikenal juga sebagai metode model terlatih yang baik dalam menangani permasalahan yang sifatnya *nonlinear*, serta mampu dalam melakukan pemodelan untuk pengenalan pola [14].

¹Dosen, Jurusan Teknik Informatika Politeknik Harapan Bersama Tegal, Jln.Mataram No.09 Pesurungan Lor Tegal 52147 INDONESIA (telp: 0283-352000; fax: 0283-350567; e-mail: oman.somantri@poltektegal.ac.id)

²Dosen, Jurusan Teknik Informatika Fakultas Ilmu Komputer Universitas Dian Nuswantoro, Jln. Nakula I No. 5-11 Semarang INDONESIA (e-mail: catur.dinus@gmail.com)

SVM pada awalnya dikembangkan untuk menyelesaikan masalah klasifikasi, kemudian dikembangkan sehingga akhirnya mempunyai kemampuan untuk mengatasi regresi dan masalah klasifikasi [15]. Selain itu SVM mempunyai kelebihan yaitu memiliki akurasi yang tinggi dengan tingkat kesalahan yang relatif kecil, kemampuan untuk model kompleks *nonlinear decision boundaries*, dan lebih cepat untuk mengatasi *over fitting* serta tidak membutuhkan data yang terlalu besar dan dapat digunakan untuk melakukan prediksi [16].

Dari kelebihan yang dimiliki oleh NN dan SVM, terdapat kelemahan yang dialami oleh kedua model tersebut, yaitu sulitnya menentukan nilai parameter sehingga metode yang digunakan adalah dengan melakukan eksperimen [17][18]. Salah satu kesulitan dalam menentukan nilai parameter adalah dalam menentukan nilai yang tepat untuk mendapatkan model yang terbaik. Hal inilah yang menjadikan dalam sebuah pemilihan nilai parameter masih digunakan eksperimen dan uji coba secara manual dalam memasukkan nilai parameter tersebut, sehingga memerlukan waktu yang sedikit lama untuk mendapatkan nilai yang terbaik. Berdasarkan kelemahan yang dimiliki oleh kedua model tersebut, maka perlu adanya sebuah pengoptimalan yang dapat membantu menentukan sebuah nilai parameter yang sesuai untuk digunakan dalam model sehingga tingkat akurasi yang dihasilkan menjadi lebih baik.

GA merupakan salah satu metode optimasi yang andal yang dapat digunakan untuk menentukan nilai parameter kontrol yang optimal untuk suatu proses tertentu [17]. Berdasarkan kelebihan yang dimiliki oleh GA, pengoptimalan dapat dilakukan sehingga model yang digunakan dapat menjadi lebih baik dengan hasil yang lebih akurat [19].

Tujuan penulisan makalah ini adalah untuk dapat meningkatkan tingkat akurasi yang dihasilkan oleh NN dan SVM dalam memprediksi permintaan energi listrik. Maka GA diusulkan untuk dapat mengoptimalkan nilai parameter dari kedua model sehingga dapat memperoleh nilai parameter yang lebih optimal dan dapat meningkatkan tingkat akurasi prediksi permintaan energi listrik menjadi lebih baik.

II. NEURAL NETWORK, SUPPORT VECTOR MACHINE, DAN ALGORITME GENETIKA

A. Neural Network (NN)

Neural Network (NN) merupakan sebuah algoritme yang meniru fungsi otak manusia. Otak manusia ini diyakini memiliki jutaan unit pengolah kecil yang bekerja secara paralel atau yang disebut juga *neuron*. *Neuron* pada otak manusia saling terhubung satu sama lain melalui koneksi *neuron*, dan setiap *neuron* mengambil *input* dari satu set *neuron* yang lainnya. Kemudian setelah mengambil *input* dari *neuron* yang lain, *input* yang masuk diproses dan melewati *output* lain untuk diproses lebih lanjut [20].

Salah satu algoritme NN yang sering digunakan adalah algoritma *backpropagation*. *Backpropagation* pertama kali ditemukan oleh Paul W pada tahun 1974, kemudian dikembangkan oleh Rumelhart dan McClelland yang diimplementasikan kedalam NN. *Backpropagation* awalnya dirancang untuk NN *feedforward*, tetapi dalam


perkembangannya metode ini diadaptasi untuk pembelajaran pada model NN [21]. Algoritme *backpropagation* masuk ke dalam metode algoritma jenis terawasi di mana metode ini bekerja dengan cara meminimalkan *error* pada *output* yang dihasilkan oleh model jaringannya.

Konsep dari algoritma *backpropagation* adalah ketika hasil *output* dari model jaringan yang dihasilkan memberikan nilai hasil yang salah, maka *weight* (bobot) dalam jaringan akan dikoreksi agar galat yang dihasilkan lebih kecil sehingga respons jaringan diharapkan akan mendekati nilai yang benar. Perbaikan bobot yang diperbaiki oleh *backpropagation* adalah pada bagian lapisan tersembunyi (*hidden layer*) [22].

B. Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah sebuah mesin linear yang dilengkapi dengan fitur-fitur khusus yang pada dasarnya adalah sebuah metode untuk meminimalkan resiko struktural dan teori pembelajaran statistik. SVM memiliki sifat-sifat yang khusus yaitu, (1) mencapai generalisasi yang tinggi dengan memaksimalkan margin; dan (2) mendukung pembelajaran yang efisien dari fungsi *nonlinear* pada trik *kernels* sehingga membuat kinerja generalisasinya menjadi baik dalam menyelesaikan masalah pengenalan pola [23].

SVM dikembangkan oleh Boser, Guyon, Vapnik dan pertama kali dipresentasikan pada tahun 1992. Konsep SVM pada dasarnya adalah sebagai usaha mencari *hyperlane* terbaik yang berfungsi sebagai pemisah dua buah *class* pada *input space*, ditunjukkan seperti pada Gbr. 1.



Gbr. 1 *Hyperlane Class -1 dan +1*.

Pada Gbr. 1 diperlihatkan bahwa beberapa *pattern* merupakan anggota dari dua buah *class* yaitu +1 dan -1. *Pattern* yang tergabung pada class -1 disimbolkan dengan warna merah (kotak), sedangkan *pattern* pada class +1 disimbolkan dengan warna kuning (lingkaran). Untuk masalah klasifikasi dapat diterjemahkan dengan usaha menemukan garis (*hyperlane*) yang memisahkan antara kedua kelompok tersebut. *Hyperlane* pemisah terbaik antar kedua *class* dapat ditemukan dengan mengukur margin *hyperlane* tersebut dan mencari titik maksimalnya. Margin sendiri adalah jarak antara *hyperlane* tersebut dengan *pattern* terdekat dari masing-masing *class*, sedangkan *pattern* yang paling dekat inilah yang disebut dengan *support vector* [24].

C. Algoritme Genetika

Algoritme genetika atau *Genetic Algorithm* (GA) adalah sebuah algoritme untuk optimasi yang didasarkan pada prinsip proses genetika dan seleksi alam dan merupakan bagian dari

bagian komputasi evolusioner yang berkembang saat ini dalam bidang kecerdasan buatan [25].

Konsep algoritme genetika terinspirasi dari sebuah mekanisme seleksi alam, di mana individu yang lebih kuat berkemungkinan akan menjadi pemenang dalam lingkungannya. Solusi yang optimal dapat diperoleh dari pemenang akhir dari proses genetika tersebut atau sering disebut juga *fitness*. Solusi yang diperoleh pada algoritme genetika diterapkan pada sebuah populasi individu yang mewakili dari solusi masing-masing individu yang mewakili dari solusi yang mungkin, yang disebut kromosom.

Inti dari GA adalah mengkodekan satu set parameter (gen) dan gabungan dari gen-gen yang membentuk nilai-nilai tertentu dan menyatakan solusi yang mungkin dari suatu permasalahan (kromosom). Fungsi *fitness* diperlukan untuk memberikan nilai yang diperoleh dari setiap solusi dan setiap individu bergantung pada kromosom dan dievaluasi oleh fungsi *fitness* [26].

III. METODOLOGI

A. Dataset

Dataset yang digunakan berasal dari data publik terkait dengan permintaan konsumsi energi listrik yang diambil dari www.aemo.au, sebuah situs yang bernama *Australian Energi Market Operator* (AEMO). *Dataset* yang digunakan adalah data permintaan kebutuhan energi listrik di Negara Australia bagian wilayah Victoria dalam kurun waktu tiga bulan pada tahun 2013, yaitu mulai tanggal 1 Oktober 2013 jam 00.00.00 AM sampai dengan tanggal 31 Desember 2013 jam 11.30.00 PM yang terdiri atas lima atribut, di antaranya adalah *REGION* (wilayah), *SETTLEMENTDATE* (tanggal dan waktu), *TOTALDEMAND* (permintaan listrik), *RPP* (harga listrik) dan *PERIODTYPE* (keterangan) dengan jumlah data *record* sebanyak 4416 *record* data.

Adapun *dataset real* yang diperoleh adalah seperti pada Tabel I.

B. Praprosesing Data

Sebelum *dataset* yang akan digunakan dimasukkan ke dalam model yang akan digunakan, maka terlebih dahulu dilakukan *praprosesing* data, yaitu dengan melakukan beberapa hal, di antaranya (1) pemilihan variabel yang sesuai; (2) penentuan data *input* dan *output*; dan (3) penentuan data *training* dan *testing*.

1) *Pemilihan Atribut*: Pada proses ini dilakukan pemilihan atribut dari data *real* yang sudah diperoleh sehingga *dataset* yang akan digunakan pada model sudah sesuai dengan model yang akan digunakan. Pada proses ini telah dipilih dua atribut yang sesuai yaitu *Settlement date* dan *Total demand*. *Dataset* yang telah dipilih tampak seperti pada Tabel II.

2) *Penentuan Data Input dan Output*: Pada proses ini yang dilakukan adalah pemilihan data yang akan dijadikan sebagai *input* dan data yang akan dijadikan sebagai *output*. Seperti yang terlihat bahwa *dataset* yang telah dipilih adalah *univariate*, maka data dijadikan *multivariate* terlebih dahulu. Melalui konsep *windowing*, data diubah menjadi *multivariate*

yang dalam hal ini atribut yang diubah adalah *Totaldemand*. Tabel III menunjukkan data setelah menjadi *multivariate*. Data *input* yang digunakan sebanyak sepuluh atribut, sedangkan untuk *output* sebanyak satu atribut.

TABEL I
DATASET REAL PERMINTAAN ENERGI LISTRIK AEMO, 2013

Region	Settlement date	Total demand	RPP	Period type
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 23:00	4515.98	43.34	TRADE
VIC1	12/31/2013 23:30	4890.53	44.33	TRADE

TABEL II
DATASET HASIL PEMILIHAN ATRIBUT YANG SESUAI

Settlement date	Total demand
10/1/2013 0:30	4874.85
10/1/2013 1:00	4431.29
10/1/2013 1:30	4285.57
10/1/2013 2:00	4183.53
10/1/2013 2:30	4013.24
10/1/2013 3:00	3918.24
10/1/2013 3:30	3823.37
10/1/2013 4:00	3798.98
...	...
...	...
12/31/2013 23:00	4515.98
12/31/2013 23:30	4890.53

3) *Data Training dan Testing*: Data *training* dan *testing* diambil dari 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 jam 00:00:00 AM s.d 31 Desember 2013 jam 11:30:00 PM. *Dataset* kemudian dibagi menjadi dua bagian dengan persentase pembagian data 90% untuk data *training* dan 10% untuk data *testing*.

C. Metode Yang Diusulkan

Metode yang diusulkan adalah untuk dapat meningkatkan tingkat akurasi prediksi permintaan kebutuhan energi listrik diusulkan GA sebagai model yang akan diterapkan. GA digunakan untuk mendapatkan nilai parameter terbaik yang nantinya digunakan pada NN dan SVM, sehingga terjadi peningkatan akurasi menjadi lebih optimal.

Untuk mendapatkan model yang diinginkan dari metode yang diusulkan, digunakan *tools* RapiR Miner 5. Validasi model menggunakan *K-folds validations*, untuk mencari nilai *Root Mean Squared Error* (RMSE).

TABEL III
DATASET SETELAH MENJADI MULTIVARITE

Settlement date	X1	X2	X3	Xn	Label
Tue Oct 01 04:30:00 ICT 2013	5282.28	4874.9	3885.59
Tue Oct 01 05:00:00 ICT 2013	4874.85	4431.3	3988.05
Tue Oct 01 05:30:00 ICT 2013	4431.29	4285.6	4194.51
Tue Oct 01 06:00:00 ICT 2013	4285.57	4183.5	4633.39
Tue Oct 01 06:30:00 ICT 2013	4183.53	4013.2	4927.45
Tue Oct 01 07:00:00 ICT 2013	4013.24	3918.2	5064.41
Tue Oct 01 07:30:00 ICT 2013	3918.24	3823.4	5374.62
Tue Oct 01 08:00:00 ICT 2013	3823.37	3799	5555.13
Tue Oct 01 08:30:00 ICT 2013	3798.98	3824.5	5598.18
Tue Oct 01 09:00:00 ICT 2013	3824.47	3885.6	5623.2
Tue Oct 01 09:30:00 ICT 2013	3885.59	3988.1	5568.7
Tue Oct 01 10:00:00 ICT 2013	3988.05	4194.5	5609.96
...
...

Gambaran metode yang diusulkan ditunjukkan pada Gbr. 2. Pada Gbr. 2, GA digunakan untuk mencari nilai parameter terbaik dan optimal dari model NN dan SVM. Model yang diusulkan divalidasi dengan menggunakan 10 *Fold Cross Validation* sehingga akan didapatkan nilai RMSE yang terbaik dari kedua model.

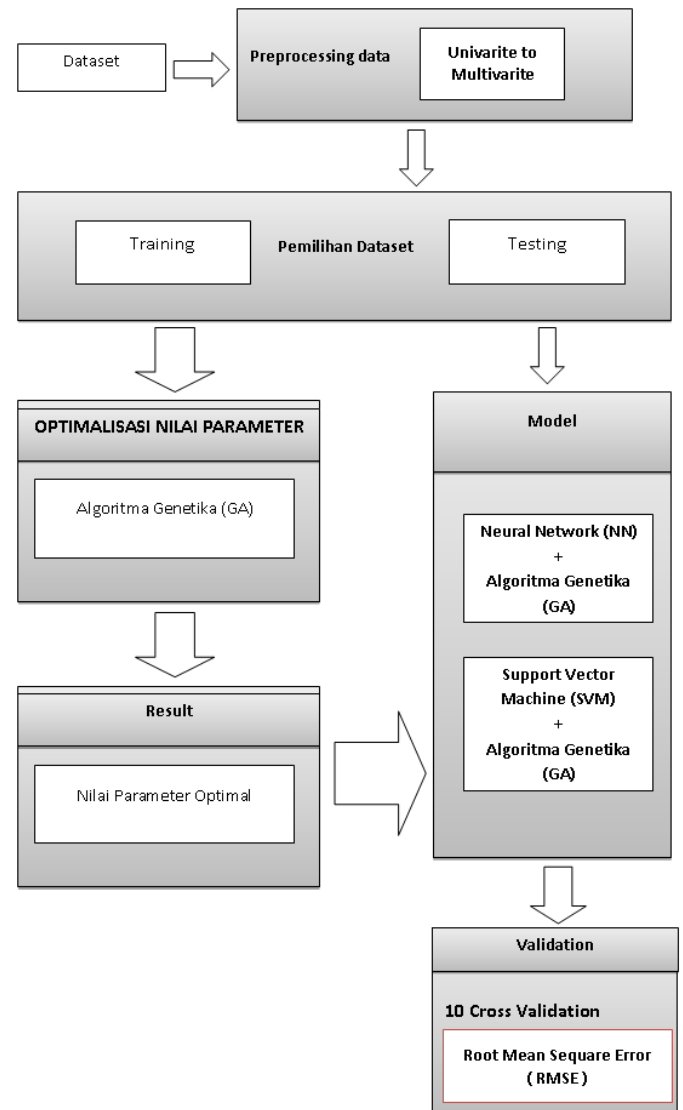
Evaluasi terhadap model yang diusulkan untuk mengetahui apakah model yang diusulkan berhasil, maka evaluasi dilakukan dengan cara membandingkan hasil nilai RMSE model NN dan SVM, dengan NN menggunakan GA serta SVM dengan menggunakan GA.

IV. HASIL DAN PEMBAHASAN

A. Hasil Eksperimen

Pada eksperimen ini, digunakan komputer dengan spesifikasi *processor* CPU Intel Core i5 2.67 GHz, RAM 4 GB, serta sistem operasi Windows 7 Professional 32-bit.

Setelah dilakukan eksperimen, didapatkan beberapa hasil terkait dengan model yang diusulkan. Ekperimen dilakukan melalui empat tahapan, yaitu (1) eksperimen dilakukan dengan mencari model terbaik NN tanpa GA; (2) mencari model terbaik SVM tanpa GA; (3) mencari model terbaik NN dengan GA; dan (4) ekperimen mencari model terbaik SVM dengan GA khusus.



Gbr. 2 Metode yang diusulkan.

B. Hasil Model SVM terbaik


Ekperimen dilakukan dengan memasukan *dataset* untuk data *training* pada model SVM dengan terlebih dahulu mengatur parameter pada SVM untuk mendapatkan nilai RMSE terbaik untuk memprediksi permintaan kebutuhan energi listrik. Nilai parameter SVM diatur untuk *parameter kernel type do* dan *type polynomial* di set *kernel cache* = 200, *C* = 0.0, *Convergence epsilon* = 0.001, dan *max iteration* = 100000. Setelah dilakukan eksperimen, didapatkan nilai RMSE = 311.032 untuk kernel tipe *Dot* dan RMSE = 700.649 untuk tipe *kernel polynomial*. Sedangkan untuk *parameter*

kernel type radial diatur kernel gamma = 1.0, kernel cache = 200, C = 0.0, Convergence epsilon = 0.001, max iteration = 100000, dan epsilon = 0.0. Setelah dilakukan eksperimen, didapatkan nilai RMSE = 641.418. Hasil eksperimen terhadap model SVM diperlihatkan pada Tabel IV.

TABEL IV
HASIL EKPERIMEN SVM

No.	Type Kernel	RMSE
1	Dot	311.032
2	Radial	641.418
3	Polynomial	700.649
Rata-Rata		551.033


Apabila dibuatkan grafik akan tampak seperti Gbr. 3 berikut ini.



Gbr. 3 Grafik perbandingan RMSE model SVM.

C. Hasil Model NN terbaik

Pada eksperimen terhadap model NN dengan menggunakan dataset yang telah ditentukan sebagai data training, didapatkan model arsitektur NN seperti Gbr. 4.



Gbr. 4 Arsitektur Neural Network yang dihasilkan.

Pada Gbr. 4 terlihat bahwa data input yang digunakan sebanyak sepuluh neuron input dan untuk output dihasilkan satu neuron output serta dihasilkan juga tujuh neuron hidden layer. Pada eksperimen ini ditetapkan nilai parameter yang terbaik adalah Training Cycles = 500, Learning rate = 0.2, dan Momentum = 0.2 dengan menghasilkan nilai RMSE = 97.174.

D. SVM dengan GA

Ekperimen dilakukan dengan menambahkan GA, dalam hal ini GA digunakan untuk mencari dan mendapatkan nilai parameter yang optimal untuk dapat meningkatkan nilai RMSE prediksi permintaan kebutuhan energi listrik. Adapun parameter GA diatur seperti pada Tabel V.

TABEL V
NILAI PARAMETER ALGORITMA GENETIKA PADA SVM

Parameter	Value
Max generations	50
Population size	5
Mutation type	Gaussian_mutation
Selection type	Roulette wheel
Crossover prob	0.9

Pengoptimalan nilai parameter yang dioptimasi oleh GA pada SVM di antaranya adalah nilai C, epsilon, dan max iteration. Setelah dilakukan eksperimen maka hasil yang didapatkan pada eksperimen setelah menerapkan GA pada SVM adalah nilai parameter dan RMSE terbaik sebagai berikut:

- SVM.C = 0.9237383495738495
- SVM.epsilon = 0.06383184705968506
- SVM.max_iterations = 70
- RMSE = 215.158

E. Neural Network dan GA

Pada pengujian yang dilakukan untuk mendapatkan nilai parameter terbaik dari NN, parameter GA diatur hampir sama dengan nilai parameter GA pada SVM, yaitu Max generations = 50, Population size = 5, Mutation type = Gaussian_mutation, Selection type = Roulette wheel, dan Crossover prob = 0.9.

Ekperimen yang dilakukan menghasilkan kesimpulan, berdasarkan analisis pengujian antara model NN dengan NN berbasis GA, hasilnya seperti pada Tabel VI.

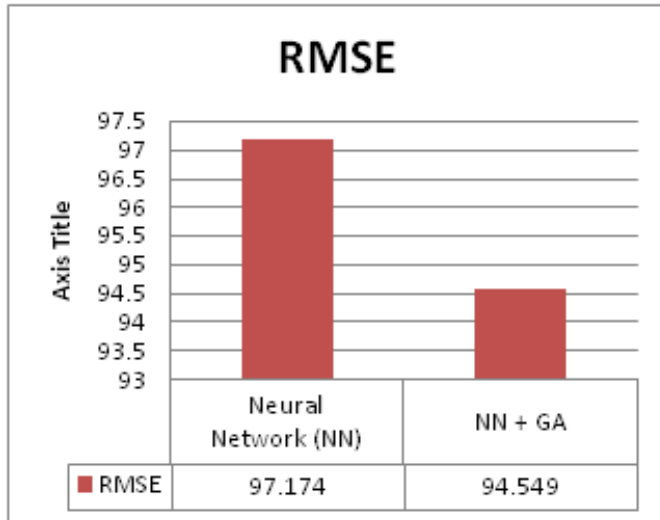
TABEL VI
HASIL ANALISIS DAN KOMPARASI NN DENGAN NN + GA

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

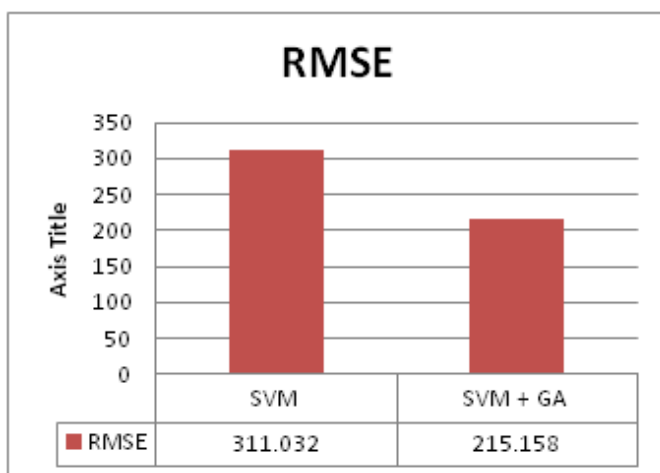
Berdasarkan hasil analisis dalam eksperimen yang telah dilakukan, terlihat bahwa dengan adanya pengoptimalan penentuan parameter NN menggunakan GA nilai prediksi RMSE menjadi sebesar 2.625, dengan nilai parameter terbaik nilai learning rate = 0.18347049067245383 dan nilai momentum = 0.3717224921578156.

TABEL VII
HASIL ANALISIS DAN KOMPARASI NN DENGAN NN + GA

Model	RMSE
SVM	311.032
Neural Network (NN)	97.174
SVM + GA	215.158
NN + GA	94.549



Gbr. 5 Grafik perbandingan NN dan NN + GA.



Gbr. 6 Grafik perbandingan SVM dan SVM + GA.

F. Evaluasi

GA pada penelitian ini diterapkan untuk mengoptimalkan tingkat akurasi prediksi kebutuhan permintaan energi listrik. Optimasi dilakukan dengan mencari nilai parameter terbaik yang digunakan oleh model yaitu NN dan SVM. Hasil menunjukkan terjadinya perubahan tingkat akurasi, dan hasilnya dapat dilihat pada Tabel VII.

Pada Gbr. 5 terlihat adanya perubahan nilai RMSE yaitu NN sebesar 97.174 dan NN+GA sebesar 94.549. Maka, dari eksperimen tersebut diketahui GA dapat meningkatkan tingkat akurasi. Terlihat juga bahwa terjadi penurunan nilai RMSE dan itu artinya terdapat adanya peningkatan akurasi.

Gbr. 6 memperlihatkan adanya sebuah perbedaan nilai RMSE antara SVM sebesar 311.032 dengan SVM + GA sebesar 215.158. Dari perbedaan tersebut terlihat bahwa GA mampu meningkatkan tingkat akurasi pada SVM dengan ditandai adanya perubahan nilai RMSE yang lebih kecil dibandingkan dengan sebelumnya, yaitu RMSE sebesar 215.158.

V. KESIMPULAN

Penelitian yang dilakukan mengusulkan GA sebagai model yang digunakan untuk mengoptimasi nilai parameter terbaik dari model yang ada yaitu NN dan SVM dalam memprediksi permintaan kebutuhan energi listrik. Dengan kedua model tersebut, dari hasil penelitian, dapat disimpulkan bahwa GA dapat mengoptimasi prediksi permintaan kebutuhan energi listrik, sehingga terjadi peningkatan akurasi dan dapat menentukan nilai parameter terbaik yang digunakan dalam model. Dengan adanya pengoptimalan prediksi maka para pengambil kebijakan terkait dalam penentuan harga listrik dan kebutuhannya dapat menentukan prediksi dengan lebih tepat. Berdasarkan penelitian yang dilakukan, NN dengan menggunakan GA merupakan model yang lebih baik dibandingkan dengan SVM dan GA.

Penelitian yang dilakukan belumlah cukup untuk dapat menentukan ketepatan akurasi prediksi. Terdapat beberapa model optimasi yang dapat digunakan. Untuk penelitian selanjutnya, optimasi terhadap model yang diusulkan dapat dilakukan eksperimen-eksperimen lain dengan menggunakan algoritme lain sehingga terdapat perubahan dalam tingkat akurasi yang dihasilkan, sehingga prediksi nilai RMSE yang dihasilkan menjadi lebih baik lagi.

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), pp.1332 – 1338
- [3] Council, E.P.A., "Directive 2010/31/EU of the European Parliament and of the Council of 19 May, 2010 on the energy performance of buildings". *Official Journal of the European Union*; 2010, pp.13–35.
- [4] L. Ekonomou, "Greek Long-Term Energy Consumption Prediction Using Artificial Neural Networks", *Energy* 35, (2010), pp. 512–517
- [5] Yang L, Lam JC, Tsang CL. "Energy performance of building envelopes in different climate zones in China". *Appl Energy* 2008; 85: 800–17.
- [6] 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), p.102
- [7] 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, pp.1001–8.109
- [8] R.E. Abdel-Aal, "Univariate modeling and forecasting of monthly energy demand time series using abductive and neural networks", *Computers & Industrial Engineering* 54, (2008), 903–917
- [9] Zhao H-X, Magoulès F. "A review on the prediction of building energy consumption. *Renew Sustain Energy Rev* ", 2012 ;16(6) : 3586–92.
- [10] Lee Yi-Shian, Tong L-I. "Forecasting timeseries using a methodology based on autoregressive integrated moving average and genetic programming." *Knowl- Based Syst* 2011; 24(1) : 66–72.

- [11] Mohammed El-Telbany & Fawwaz El-Karmi, "Short-Term Forecasting Of Jordanian Electricity Demand Using Particle Swarm Optimization", *Electric Power Systems Research* 78 , 2008, pp. 425–433
- [12] Mehmet Bilgili, Besir Sahin, Abdulkadir Yasara & Erdogan Simseka, "Electric energy demands of Turkey in residential and industrial sectors", *Renewable and Sustainable Energy Reviews* 16, (2012), pp. 404–414
- [13] 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), pp. 425–441
- [14] Fausett, L., *Fundamental Of Neural Network Architecture, Algorithms, And Applications*. New Jersey: Prentice Hall, 1994.
- [15] Shi, Y., Tian, Y., & Kou, G., *Optimization Based Data Mining Theory and Applications*. (xx, Ed.). Springer London., 2011.
- [16] Ilhan, I., & Tezel, G., "A Genetic Algorithm-Support Vector Machine Method With Parameter Optimization For Selecting The Tag SNPs". *Journal of Biomedical Informatics*, 46(2), 2013.
- [17] Wu, G., "Research on Parameter Optimization of Neural Network". *International Journal of Hybrid Information Technology* Vol. 2, No. 1, January, 2009, 81.
- [18] Moro, S., & Laureano, R. M. S., "Using Data Mining for Bank Direct Marketing: An application of the CRISP-DM methodology". *European Simulation and Modelling Conference*, (Figure 1), pp.117–121, 2012.
- [19] Haupt, R. L. ., & Haupt, S. E., *Practical Genetic Algorithms* (Second Edi.). New Jersey: A John Wiley and Sons, Ltd., 2004.
- [20] Shukla, A., Tiwari, R., & Kala, R., *Real Life Applications of Soft Computing*. New York: CRC Press, 2010.
- [21] Astuti, E. D. *Pengantar Jaringan Saraf Tiruan*. Wonosobo: Star Publishing, 2009.
- [22] Purnomo, M. H., & Kurniawan, A., *Supervised Neural Network*. Surabaya: Graha Ilmu, 2006.
- [23] Gorunescu, F., *Intelligent Systems Reference Library*. (Gorunescu, Ed.), 2011.
- [24] Cortes, C., & Vapnik, V., "Support vector machine". In *Machine learning* (pp. 1303–1308). doi:10.1007/978-0-387-730035_299, 1995.
- [25] Purnomo, M. H., & Kurniawan, A., *Supervised Neural Network*. Surabaya: Graha Ilmu, 2006.
- [26] Weise, T., *Global Optimization Algorithms – Theory and Application (Second Edition)*. it-weise.de (self-published), 2009.