

repository.ub.ac.id

PRAKIRAAN KEBUTUHAN ENERGI LISTRIK MENGGUNAKAN SUPPORT VECTOR REGRESSION (SVR) DENGAN OPTIMASI ALGORITMA GENETIKA (STUDI KASUS PLN KOTA MALANG)

Tanti Meta Sari¹⁾, Imam Cholissodin, S.Si.,M.Kom²⁾, Budi Darma Setiawan, S.Kom, M.Cs³⁾

Program Studi Teknik Informatika
Program Teknologi Informasi dan Ilmu Komputer
Universitas Brawijaya, Malang 65145, Indonesia
email : [tantimetasari\[at\]gmail.com](mailto:tantimetasari@gmail.com)¹⁾, [imam.cs\[at\]ub.ac.id](mailto:imam.cs[at]ub.ac.id)²⁾, [s.budidarma\[at\]ub.ac.id](mailto:s.budidarma[at]ub.ac.id)³⁾

Abstrak

Listrik merupakan salah satu kebutuhan manusia yang paling penting. Hampir semua kegiatan manusia membutuhkan energi listrik. Tingginya kebutuhan konsumsi manusia akan listrik menyebabkan semakin tingginya konsumsi listrik yang dibutuhkan. Kota Malang merupakan salah satu kota yang memiliki penduduk yang besar yaitu 973.716 jiwa per tanggal 1 Juli 2015. Dengan besarnya jumlah penduduk Kota Malang maka berbanding lurus dengan kebutuhan akan konsumsi listrik. Mengingat konsumsi listrik Kota Malang yang cenderung meningkat terus menerus setiap bulannya, maka dibutuhkan perancangan kedepannya untuk membangun pembangkit listrik baru jika sewaktu-waktu jumlah konsumsi listrik melebihi batas maksimum yang mampu disediakan. Namun untuk membangun pembangkit baru memerlukan biaya yang sangat besar dan perancangan yang sangat matang. Oleh karena prakiraan konsumsi energi listrik sangat diperlukan untuk membantu membuat keputusan dalam membangun pembangkit listrik. Dengan demikian prakiraan kebutuhan konsumsi listrik merupakan langkah tepat untuk mengantisipasi kebutuhan energi listrik yang diduga akan bertambah setiap bulannya. Namun, pihak PLN belum memiliki sistem yang mumpuni untuk memperkirakan kebutuhan energi listrik Kota Malang. Banyak teknik prakiraan atau peramalan yang dapat digunakan untuk memprakiraan jumlah konsumsi listrik, salah satunya adalah *Support Vector Regression* (SVR). SVR adalah pengembangan dari Support Vector Machine untuk masalah prakiraan dan peramalan untuk kasus regresi. *Support Vector Regression* meminimalisir pembatasan dikarenakan metode ini memungkinkan penggunaan fungsi non-linier. Berdasarkan permasalahan beserta solusi dari beberapa penelitian sebelumnya, dirasa belum optimal. Saat ini, banyak metode baru untuk melakukan optimasi yang dirasa mampu menyelesaikan permasalahan di atas. Salah satu algoritma yang dapat digunakan untuk optimasi adalah algoritma genetika. Algoritma genetika adalah metode ilmiah heuristik yang didasarkan pada teori evolusi biologis Darwin. Sesuai dengan pengujian yang dilakukan menggunakan data yang didapat dari PLN Kota Malang berupa konsumsi kebutuhan listrik (kWh) dari tahun 2010 hingga 2014, metode SVR yang dioptimasi dengan algoritma genetika dapat menghasilkan MAPE dengan nilai 0.161741.

Kata Kunci : Konsumsi Listrik, kWh, Kota Malang, SVR, Algoritma Genetika, MAPE.

Abstract

Electricity is one of the most important human needs. Almost all human activities requiring electricity. The high demand for human consumption for electricity contributed to greater consumption of electricity needed. Malang is a city that has a large population is 973.716 inhabitants as of July 1, 2015. With a large population of Malang then directly proportional to the electricity consumption requirements. Considering Malang electricity consumption which tend to increase continuously every month, it takes planning to build new power plants if at any time the amount of electricity consumption exceeds the maximum limit able to be provided. However, to build new power plants require huge funds and careful design. Thus, forecasts of electricity consumption is the right step to anticipate the needs of the electrical energy which is expected to increase each month. However, PLN doesn't have a capable system to estimate the electrical energy needs of Malang. Many forecasting techniques that can be used to estimate the amount of electricity consumption such as Support Vector Regression (SVR). SVR is the development of Support Vector Machine to issue forecasting for the case of regression. Support Vector Regression minimize restriction because this method allows the use of non-linear functions. Based on the problems and solutions of some previous studies, deemed not optimal. Today, many new methods to perform optimization felt able to solve the problems above. One algorithm that can be used for optimization is a genetic algorithm. Genetic algorithm is heuristic scientific method that is based on Darwin's theory of biological evolution. According to tests performed using data obtained from PLN Malang in the form of consumption demand for electricity (kWh) from 2010 to 2014, SVR method optimized with genetic algorithm can produce MAPE with a value of 0.161741

Keywords : Electricity Consumption, kWh, Malang City, SVR, Genetic Algorithm, MAPE.

UNIVERSITAS BRAWIJAYA

1. PENDAHULUAN

Kota Malang merupakan salah satu kota berkembang yang ada di Jawa Timur. Kota Malang memiliki jumlah penduduk yang besar dan meningkat setiap tahunnya. Menurut Dinas Kependudukan dan Pencatatan Sipil Kota Malang per tanggal 1 Juli 2015, jumlah penduduk Kota Malang mencapai 873.716 jiwa. Sebagai kota yang padat dan sibuk, Kota Malang membutuhkan pasokan listrik yang besar. Hal ini dikarenakan Kota Malang memiliki 31 Perguruan Tinggi dan 83 Industri Besar dan Sedang.

Kebutuhan akan listrik memegang peranan penting dalam melakukan kegiatan sehari-hari sehingga diperlukan perhatian khusus dalam menanganinya. Seiring dengan peningkatan kegiatan sektor industri dan pendidikan, penggunaan listrik pun mengalami peningkatan. Untuk memenuhi kebutuhan warga akan listrik, maka pihak penyuplai energi listrik dalam hal ini adalah PLN perlu melakukan pengembangan penyediaan tenaga listrik seperti pembangunan pembangkit baru yang memerlukan waktu yang lama dan biaya yang besar dan diusahakan agar daya yang dibangkitkan cukup untuk memenuhi kebutuhan konsumen. Peningkatan konsumsi listrik tersebut akan berakibat fatal jika tidak ditangani dengan baik. Oleh karena prakiraan konsumsi energi listrik sangat diperlukan untuk membantu membuat keputusan dalam membangun pembangkit listrik. Dengan demikian prakiraan kebutuhan konsumsi listrik merupakan langkah tepat untuk mengantisipasi kebutuhan energi listrik yang diduga akan bertambah setiap bulannya.

Peramalan kebutuhan konsumsi listrik yang tepat dapat memberikan keuntungan pada segi ekonomi dan efisien dalam melakukan pendistribusian listrik. Pembangunan pembangkit listrik yang salah dapat menyebabkan kerugian besar. Jika pembangunan pembangkit listrik lebih sedikit dari kebutuhan konsumsi listrik, maka dapat menyebabkan krisis listrik. Sebaliknya, jika melebihi kebutuhan konsumsi listrik maka menyebabkan beban listrik yang besar sehingga membuang-buang sumber daya^[18].

Untuk saat ini, pihak PLN Kota Malang belum mempunyai sistem untuk memprakirakan kebutuhan energi listrik. Mereka hanya menggunakan rumus rata-rata sederhana untuk memperkirakan penggunaan hari berikutnya. Sistem mereka hanya memprakirakan kebutuhan energi listrik dalam jumlah hari, tidak bulan atau tahun. Hal itu menunjukkan bahwa pihak PLN Kota Malang hanya bisa memprakirakan kebutuhan energi listrik dalam jangka pendek. Untuk itu diperlukan sebuah sistem

yang mampu memprakirakan kebutuhan energi listrik untuk jangka panjang.

Banyak teknik prakiraan atau peramalan yang dapat digunakan untuk memprakiraan jumlah konsumsi listrik^{[2][3][6][20]}. Prakiraan jumlah konsumsi listrik ini termasuk pada kasus regresi. Regresi tradisional atau regresi linier sering dinyatakan memiliki penyimpangan paling sedikit. Support Vector Regression (SVR) adalah pengembangan dari Support Vector Machine untuk masalah prakiraan dan peramalan untuk kasus regresi. Support Vector Regression meminimalisir pembatasan dikarenakan metode ini memungkinkan penggunaan fungsi non-linier^[11].

Salah satu paper membahas analisis implementasi jaringan syaraf adaptif untuk peramalan kebutuhan energi listrik di wilayah Malang^[12]. Sedangkan Ogcu et al.(2012) membahas tentang peramalan konsumsi listrik menggunakan jaringan syaraf dan support vector regression. Selain itu terdapat juga yang membuat algoritma penjadwalan untuk mengurangi ledakan konsumsi listrik^[9]. Tiga penelitian diatas menjadi referensi untuk penelitian skripsi ini.

Berdasarkan permasalahan beserta solusi dari beberapa penelitian sebelumnya, dirasa belum optimal. Saat ini, banyak metode baru untuk melakukan optimasi yang dirasa mampu menyelesaikan permasalahan di atas. Salah satu algoritma yang dapat digunakan untuk optimasi adalah algoritma genetika. Oleh karena itu algoritma genetika dirasa dapat mengoptimasi masalah regresi di atas. Pada penelitian sebelumnya yang dilaksanakan di Universitas Muhammadiyah Malang, dilakukan optimasi titik pusat cluster pada Fuzzy C-Means menggunakan algoritma genetika untuk menentukan nilai akhir mahasiswa^[10]. Penelitian tersebut menghasilkan bahwa Genetic Fuzzy System menghasilkan nilai fungsi objektif yang lebih kecil daripada Fuzzy C-Means. Dari beberapa proses tersebut diyakini Algoritma Genetika memiliki beberapa kelebihan dibandingkan algoritma yang lain dalam menghasilkan output yang optimal dan dapat dimanfaatkan untuk menyelesaikan permasalahan di atas.

2. DASAR TEORI

2.1 Daya Listrik

Daya adalah nilai dari energi listrik yang dikirkirkan dan didistribusikan, dimana besarnya daya listrik tersebut sebanding dengan perkalian besarnya tegangan dan arus listriknya. Sistem suplai daya listrik dapat dikendalikan oleh kualitas dari tegangan, dan tidak dapat dikendalikan oleh arus listrik sebab arus listrik berada pada sisi beban yang

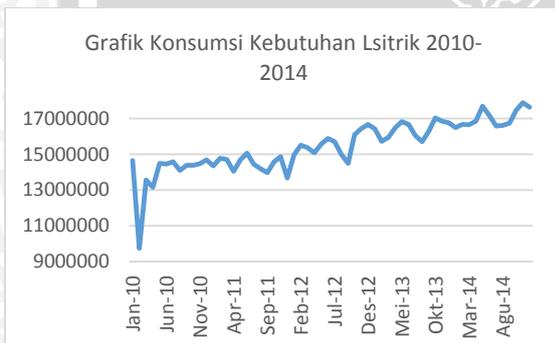
bersifat individual, sehingga pada dasarnya kualitas daya merupakan kualitas dari tegangan itu sendiri.

Daya listrik merupakan suatu besarnya usaha yang dilakukan oleh sumber tegangan dalam 1 detik. Jika dalam waktu t sekon sumber tegangan telah melakukan usaha sebesar W. Daya listrik bisa juga disebut suatu kekuatan yang dikandung dalam aliran arus dan tegangan listrik melalui hambatan dengan besaran tertentu. Satuan ukuran daya listrik adalah Watt dan mempunyai simbol P. Maka persamaan untuk mencari besarnya daya adalah^[19]:

$$P = \frac{W}{t} \dots\dots\dots(1)$$

2.1.1. kWh Listrik

KWh bisa juga disebut kilowatt-jam atau kilowatt-hour merupakan ukuran satuan energi listrik yang dikirim oleh peralatan elektronik yang terhubung dan membutuhkan listrik dan diberi biaya. KWh adalah produk tenaga listrik dalam satuan kilowatt dikalikan dengan waktu dalam jam, bukan kilowatt per jam (Kw per hour). Konsumsi kebutuhan listrik Kota Malang dari kurun waktu 2010 hingga 2014 ditampilkan dalam bentuk grafik yang akan ditunjukkan pada Gambar 1, dengan titik terkuat pada tahun 2012 dan titik terlemah nilai tukar terjadi pada tahun 2014.



Gambar 1 Grafik Konsumsi Kebutuhan Listrik Kota Malang 2010-2014

2.2 Support Vector Regression

SVR merupakan penerapan support vector machine (SVM) untuk kasus regresi. Dalam kasus regresi output berupa bilangan riil atau kontinyu. SVR merupakan metode yang dapat mengatasi overfitting, sehingga akan menghasilkan performansi yang bagus^[14]. Pada setiap perhitungan fungsi SVR, terdapat proses sequential learning. Algoritma sequential untuk regresi dapat dilihat di bawah ini^[17]:

1. Inisialisasi $\alpha_i = 0$ dan $\alpha_i^* = 0$. Menghitung

$$[R]_{ij} = K(x_i, x_j) + \lambda^2 \dots\dots\dots(2)$$

Untuk $i, j = 1, \dots, l$

kernel yang digunakan adalah kernel RFB:

$$K(x, x') = \text{Exp}(-\|x - x'\|^2 / 2\sigma^2) \dots\dots\dots(3)$$

2. Untuk setiap data latih, $i = 1$ to l , hitung:

2.1. $E_i = y_i - \sum_{j=1}^l (\alpha_j^* - \alpha_j) R_{ij}$

2.2. $\delta\alpha_i^* = \min\{\max[\gamma(E_i - \epsilon), -\alpha_i^*], C - \alpha_i\}$
 $\delta\alpha_i = \min\{\max[\gamma(-E_i - \epsilon), -\alpha_i], C - \alpha_i\}$

2.3. $\alpha_i^* = \alpha_i^* + \delta\alpha_i^*$
 $\alpha_i = \alpha_i + \delta\alpha_i \dots\dots\dots(4)$

3. Jika data latih sudah mencapai batas iterasi, maka stop. Jika belum, kembali ke step 2.

4. Fungsi regresinya adalah

$$f(x) = \sum_{j=1}^l (\alpha_j^* - \alpha_j) (K(x_i, x_j) + \lambda^2) \dots\dots\dots(5)$$

5. Selesai

Keterangan :

- R_{ij} = merupakan matriks *kernel*.
- E_i = merupakan nilai *error* ke- i .
- y_i = merupakan nilai aktual data latih.
- γ = merupakan *learning rate*.
- α_i, α_i^* = merupakan suatu nilai formulasi.
- C = merupakan nilai kompleksitas.
- ϵ = merupakan nilai deviasi
- λ = *augmenting factor*
- x_i = merupakan data ke- i
- x_j = merupakan data

2.3 Algoritma Genetika

Algoritma genetika adalah metode ilmiah heuristik yang didasarkan pada teori evolusi biologis Darwin^{[1][5]} yang telah banyak diterapkan untuk memecahkan masalah optimasi parameter dalam bidang teknik dan ilmu pengetahuan, seperti konstruksi bangunan dan bioteknologi^[7]. Algoritma genetika adalah metode untuk memecahkan masalah optimasi baik dibatasi dan tidak dibatasi yang didasarkan pada seleksi alam, proses yang mendorong evolusi biologis^[21]. Algoritma genetika berulang kali memodifikasi sebuah populasi dari solusi individual. Algoritma genetika memilih individu secara acak dari populasi saat ini untuk menjadi orang tua dan menggunakan mereka untuk menghasilkan anak-anak untuk generasi berikutnya. Selama generasi-generasi, populasi "berkembang" menuju solusi yang optimal.

2.5.1. Reprerentasi Kromosom

Langkah awal dalam penerapan algoritma genetika adalah merepresentasikan permasalahan menjadi bentuk kromosom, yakni biasa disebut pengkodean. Penentuan jenis pengkodean yang digunakan bergantung pada bentuk permasalahan yang akan diselesaikan. Pada penelitian kali ini representasi kromosom yang digunakan adalah *Value encoding*. *Value encoding* merupakan teknik dimana setiap kromosom berupa nilai dan digunakan dimana nilai tersebut lebih kompleks dari yang dibutuhkan. Contoh value encoding terdapat pada Gambar 2.

2,3123	4,7699	3,2123	5,3535
--------	--------	--------	--------

Gambar 2 Value Encoding

2.5.2. Crossover

Crossover atau sering disebut pindah silang merupakan proses perkawinan dua kromosom parent menjadi kromosom baru (*offspring*). Jumlah kromosom dalam populasi yang mengalami persilangan ditentukan oleh parameter yang disebut dengan *crossover rate*^[16]. *Extended intermediate crossover* adalah satu metode crossover yang menghasilkan offspring dari kombinasi nilai dua induk. Misalkan P1 dan P2 adalah dua induk yang telah diseleksi untuk melakukan *crossover*, maka *offspring* C1 dan C2 bisa dibangkitkan sebagai berikut^[13]:

$$C1 = P1 + \alpha(P2 - P1)$$

$$C2 = P2 + \alpha(P1 - P2) \dots \dots \dots (6)$$

2.5.3. Mutasi

Mutasi adalah proses merubah gen dari keturunan secara random. Metode *random mutation* adalah metode mutasi yang menghasilkan offspring (anak) yang dilakukan dengan menambah atau mengurangi nilai gen terpilih dengan bilangan random yang kecil. Misalkan domain variabel xj adalah [minj, maxj] dan offspring yang dihasilkan adalah C=[x'1..x'n], maka nilai gen offspring bisa dibangkitkan sebagai berikut^[13]:

$$x'_i = x_i + r(max_i - min_i) \dots \dots \dots (7)$$

2.5.4. Seleksi

Tahap seleksi menentukan individu yang dipilih untuk kawin (reproduksi) dan berapa banyak keturunan masing-masing individu yang dipilih menghasilkan. Metode elitism selection dilakukan dengan mengumpulkan semua individu baik parent maupun offspring, kemudian barulah diseleksi dengan melihat nilai fitness tertingginya untuk dipertahankan ke generasi selanjutnya. Metode seleksi elitism menjamin individu yang terbaik akan selalu lolos^{[13][16]}.

2.4 Normalisasi Data dan Denormalisasi Data

Sebelum melakukan pelatihan dalam sistem Radial Basis Function Neural Network data input dan data uji akan di normalisasi. Normalisasi ini bertujuan untuk mendapatkan data dengan ukuran yang lebih kecil yang mewakili data yang asli tanpa kehilangan karakteristik sendirinya. Rumus dari normalisasi yaitu::

$$x' = \frac{(x-x_{min})}{x_{max}-x_{min}} \dots \dots \dots (8)$$

Sedangkan denormalisasi adalah mengembalikan ukuran data yang telah dinormalisasi sebelumnya untuk mendapatkan data yang asli. Denormalisasi dilakukan pada hasil keluaran dari pelatihan berupa prakiraan konsumsi listrik. Adapun rumus dari denormalisasi yaitu sebagai berikut :

$$x = (x' \times (x_{max} - x_{min})) + x_{min} \dots \dots \dots (9)$$

Keterangan:

x' = Hasil normalisasi data yang nilainya berkisar antara 0 dan 1.

- x = Nilai data yang akan dinormalisasi.
- x_{max} = Nilai maksimum dari dataset yang digunakan.
- x_{min} = Nilai minimum dari dataset yang digunakan.

2.5 Nilai Evaluasi

Nilai evaluasi yang digunakan adalah *Mean Absolute Percentage Error* (MAPE), dimana MAPE merupakan metode analisa untuk membandingkan hasil nilai prakiraan dengan nilai asli. Semakin kecil nilai error maka semakin kecil pula perbedaan nilai prakiraan dan nilai asli. Penjabaran rumus MAPE akan dijelaskan pada Persamaan 10^[12].

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100\% \dots \dots \dots (10)$$

Sedangkan penjabaran rumus dari nilai *fitness* ditunjukkan pada Persamaan 10^[22]

$$Fitness = \frac{100}{1+MAPE} \dots \dots \dots (11)$$

Keterangan:

- ŷ_i = Nilai hasil ramalan
- y_i = Nilai aktual

3. METODOLOGI PENELITIAN

Tahapan penelitian ini ditunjukkan pada Gambar 3. Diagram Alir Metode Penelitian seperti ditunjukkan pada Gambar 3:



Gambar 3 Diagram Alir Tahapan Penelitian

3.1 Data Penelitian

Data yang digunakan pada penelitian ini adalah data konsumsi kebutuhan listrik kota Malang mulai dari Tahun 2010 hingga 2014 (dengan rentang waktu bulanan) yang didapatkan dari PLN Rayon Kota Malang.

4. PERANCANGAN

Prakiraan konsumsi kebutuhan listrik adalah dengan membentuk model regresi. Langkah awal dalam proses ini adalah melakukan normalisasi data, setelah proses normalisasi, maka yang dilakukan adalah melakukan *training*, proses training disini menggunakan metode GA untuk mengoptimasi parameter, dan SVR untuk evaluasi nilai fitness. Setelah mencapai jumlah generasi, maka menghasilkan *best parent* yang akan dijadikan parameter untuk fase *testing* pada SVR. Dari fase testing ini dihasilkan prakiraan konsumsi kebutuhan



listrik dan *error rate* untuk fase ini. Diagram alir proses umum akan dijelaskan pada Gambar 5.

Langkah 1:

Inisialisasi data yang akan diolah, parameter SVR, dan parameter GA. Pada Gambar 4 merupakan representasi kromosom yang akan digunakan.

λ	ϵ	C	cLr
-----------	------------	-----	-------

Gambar 4 Representasi Kromosom

Langkah 2:

Normalisasi data menggunakan *min-max normalization*.

Langkah 3:

Inisialisasi *parent* awal GA. Pada Tabel 1 merupakan contoh pembangkitan *parent* awal secara *random*.

Tabel 1 Parent Awal

λ	ϵ	C	cLr
5	0.00001	0.2	0.001

Langkah 4:

Reproduksi.

Langkah 5:

Evaluasi nilai *fitness* dengan *training* pada SVR.

Langkah 6:

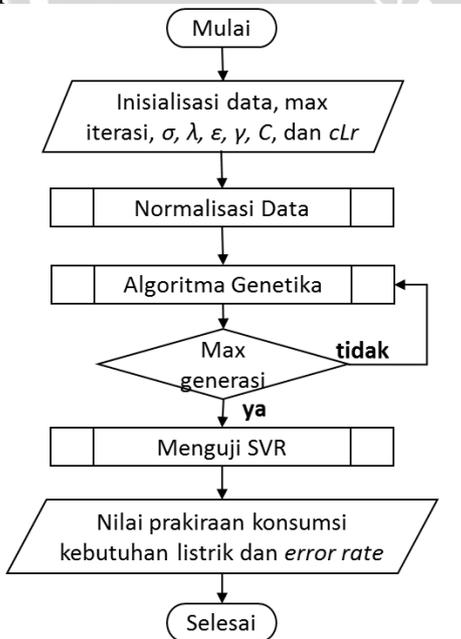
Seleksi

Langkah 7:

Setelah GA mencapai iterasi maksimum, gunakan *best parent* untuk melakukan *testing* pada SVR.

Langkah 8:

Lakukan perhitungan *error* setelah mendapatkan hasil peramalan.

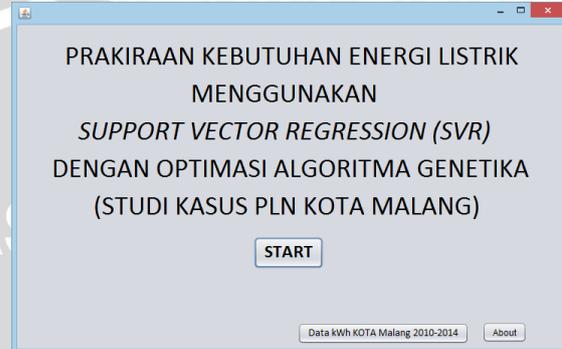


Gambar 5 Diagram Alir Proses Prakiraan Konsumsi Kebutuhan Listrik

5. IMPLEMENTASI

5.1 Halaman Training Data

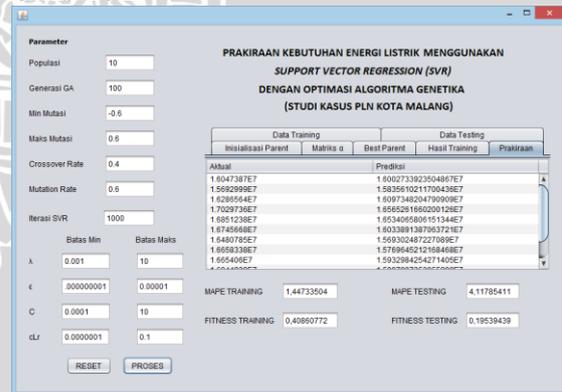
Halaman awal atau home page merupakan halaman default ketika aplikasi mulai dijalankan pertama kali. Terdapat button start untuk ke form selanjutnya dan melakukan input parameter, dan button about berisi tentang developer aplikasi. Gambar implementasi halaman awal ditunjukkan pada .



Gambar 6 Halaman Home

5.2 Halaman Proses GASVR

Halaman Proses GASVR digunakan untuk melakukan input parameter yang digunakan yaitu jumlah iterasi SVR, GA, jumlah popSize, nilai minimum dan maksimum mutasi, crossover rate, mutation rate, dan batas maksimum dan minimum parameter yang dioptimasi, terdapat button reset untuk mengosongkan nilai pada form yang tanpa perlu menghapus satu-persatu. Serta ada button proses untuk melakukan proses GASVR. Gambar implementasi halaman awal ditunjukkan pada Gambar 5.2.



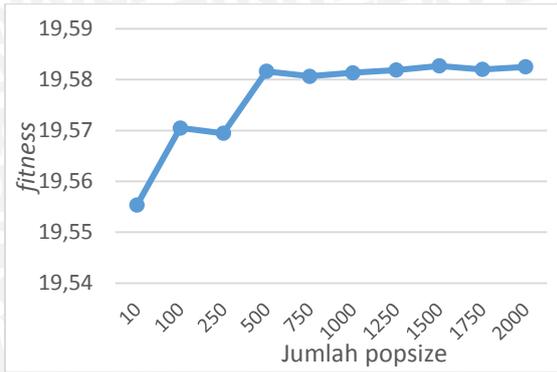
Gambar 7 Halaman Proses GASVR

6. PENGUJIAN DAN ANALISIS

a. Pengujian Jumlah PopSize

Uji coba banyaknya jumlah *popSize* yang paling optimal baik pada GA maupun pada SVR untuk memberikan hasil prakiraan yang paling baik, untuk uji coba *popSize* digunakan 10 variasi, jumlah *popSize* yang digunakan adalah 10, 20, 30, 40, 50, 60, 70, 80, 90, 100.



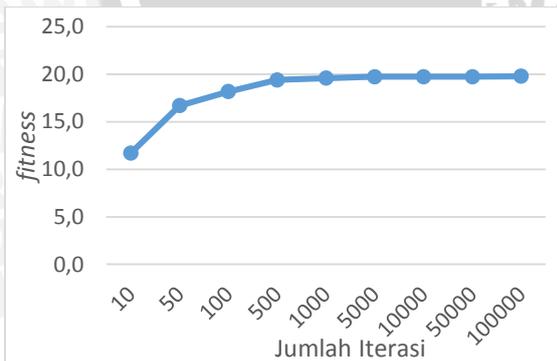


Gambar 8 Grafik Hasil Pengujian Jumlah PopSize

Pada grafik Gambar 7 dapat dilihat bahwa jumlah popSize berpengaruh terhadap perubahan nilai fitness. Secara garis besar semakin besar jumlah popSize maka nilai fitness akan semakin membesar. Untuk penambahan ukuran populasi tidak memberikan nilai fitness signifikan tetapi menunjukkan nilai fitness yang cenderung sama dengan ukuran populasi yang diindikasikan sudah mencapai konvergen. Populasi yang terlalu sedikit akan menyebabkan sedikitnya individu yang belum cukup baik akan terpilih sehingga membuat nilai fitness juga akan kurang optimal. Sebaliknya, jika semakin banyak populasi belum tentu juga didapat nilai fitness yang cukup tinggi dari jumlah populasi yang lebih sedikit [23].

b. Pengujian Jumlah Iterasi SVR

Uji coba jumlah iterasi SVR adalah uji coba untuk mengetahui jumlah iterasi SVR yang optimal agar menghasilkan prakiraan yang baik. Untuk pengujian jumlah iterasi SVR yang digunakan adalah 10, 50, 100, 500, 1000, 5000, 10000, 50000, 100000.



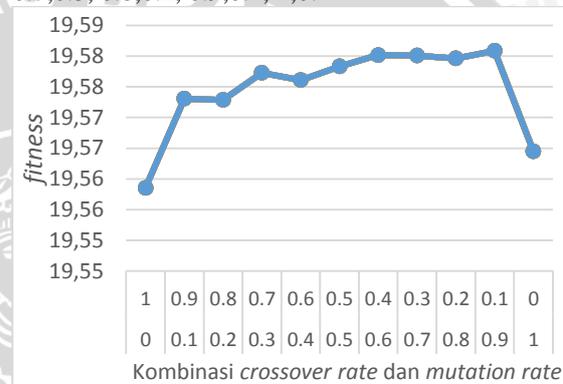
Gambar 9 Grafik Pengujian Jumlah Iterasi SVR

Pada grafik Gambar 8 dapat dilihat bahwa jumlah iterasi berpengaruh terhadap perubahan nilai fitness. Jumlah generasi/iterasi merepresentasikan lamanya proses pembelajaran yang dilakukan terhadap jaringan yang sedang diobservasi. Jumlah iterasi menentukan kapan proses pembelajaran dihentikan. Semakin besar nilai jumlah iterasi, maka semakin lama pula proses pembelajaran berlangsung. Jumlah iterasi yang terlalu sedikit, mengakibatkan alpha yang terbentuk

bersifat terlalu general/umum (overweight). Artinya kemampuan dalam mengenali pola terlalu sedikit atau bahkan tidak ada sama sekali. Jumlah generasi/iterasi yang terlalu banyak, akan mengakibatkan jaringan mengalami kondisi overfit. Dikatakan bahwa kondisi overfit akan bagus dalam mengenali pola data pelatihan namun buruk dalam mengenali pola dari data pengujian [24].

c. Pengujian Kombinasi Crossover Rate dan Mutation Rate

Untuk pengujian kombinasi crossover rate dan mutation rate adalah untuk mengetahui nilai crossover rate dan mutation rate yang baik untuk kasus regresi ini sehingga menghasilkan prediksi yang optimal. Untuk penujian nilai crossover rate dan mutation rate yang digunakan adalah 0;1, 0,1;0,9, 0,2;0,8, 0,3;0,7, 0,4;0,6, 0,5;0,5, 0,6;0,4, 0,7;0,3, 0,8;0,2, 0,9;0,1, 1;0.



Gambar 10 Grafik Pengujian Kombinasi Crossover Rate dan Mutation Rate

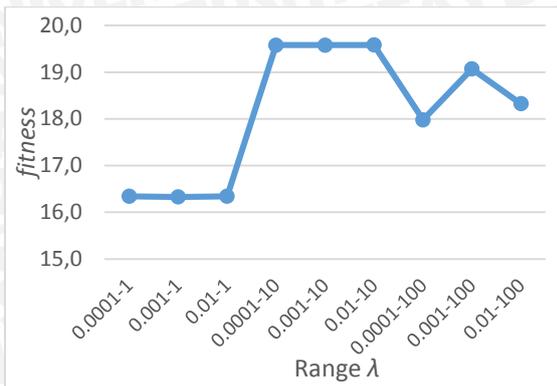
Pada Gambar 9 dapat dilihat bahwa kombinasi crossover rate dan mutation rate berpengaruh terhadap perubahan nilai fitness. Semakin besar nilai crossover rate dan semakin kecil nilai mutation rate maka nilai fitness akan semakin membesar. Crossover rate yang tinggi dan mutation rate yang rendah digunakan, maka akan mengalami penurunan kemampuan untuk menjaga diversitas populasi. Crossover rate yang tinggi akan menghasilkan offspring yang mempunyai kemiripan yang tinggi dengan induknya. Hal ini menyebabkan GA mengalami konvergensi dini hanya dalam beberapa generasi dan kehilangan kesempatan untuk mengeksplorasi area lain dalam ruang pencarian [25].

d. Pengujian Range Lambda (λ)

Untuk penujian nilai range λ yang digunakan adalah 0,0001-1, 0,001-1, 0,01-1, 0,0001-10, 0,001-10, 0,01-10, 0,0001-100, 0,001-100, 0,01-100.

Pada grafik Gambar 10 dapat dilihat bahwa range λ cukup berpengaruh terhadap perubahan nilai fitness. Nilai fitness meningkat tajam pada saat nilai maksimum 10, namun kembali turun saat nilai maksimum membesar di 100.

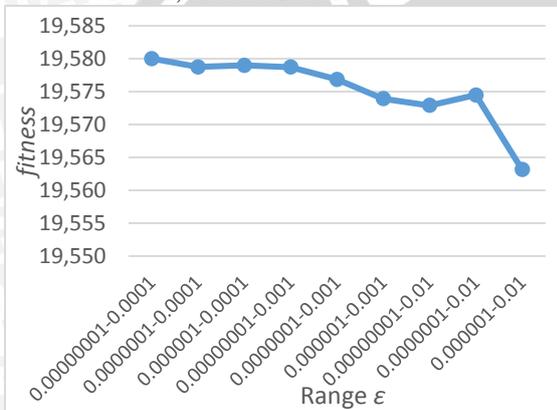




Gambar 11 Grafik Pengujian Range Lambda (λ)

e. Pengujian Range Epsilon (ϵ)

Untuk penujian nilai range λ yang digunakan adalah 0.00000001-0.0001, 0.0000001-0.0001, 0.000001-0.0001, 0.00000001-0.001, 0.0000001-0.001, 0.000001-0.001, 0.00000001-0.01, 0.0000001-0.01, 0.000001-0.01.

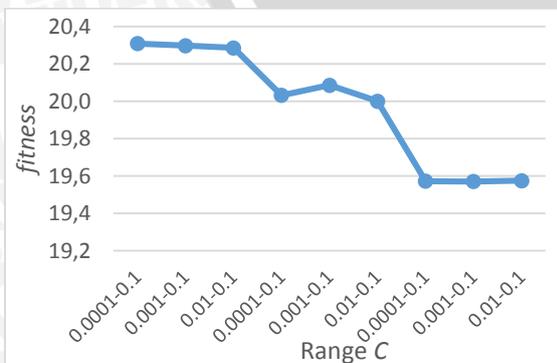


Gambar 12 Grafik Pengujian Range Epsilon (ϵ)

Pada grafik Gambar 11 dapat dilihat bahwa range ϵ berpengaruh terhadap perubahan nilai fitness. Semakin besar nilai epsilon ϵ , maka semakin jelek hasil regresinya sehingga menghasilkan nilai fitness yang semakin kecil.

f. Pengujian Range C

Untuk penujian nilai range C yang digunakan adalah 0.0001-0.1, 0.001-0.1, 0.01-0.1, 0.0001-0.1, 0.001-0.1, 0.01-0.1, 0.0001-0.1, 0.001-0.1, 0.01-0.1.



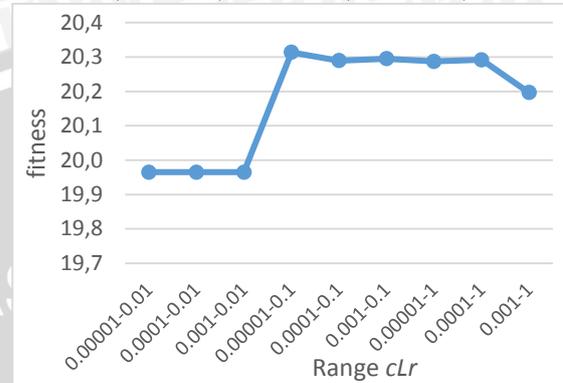
Gambar 13 Grafik Range C

Pada grafik Gambar 12 dapat dilihat bahwa range C berpengaruh terhadap perubahan nilai

fitness. Semakin besar nilai epsilon C, maka semakin jelek hasil regresinya sehingga menghasilkan nilai fitness yang semakin kecil.

g. Pengujian Range cLR

Untuk penujian nilai range cLr yang digunakan adalah 0.0001-0.1, 0.001-0.1, 0.01-0.1, 0.0001-0.1, 0.001-0.1, 0.01-0.1, 0.0001-0.1, 0.001-0.1, 0.01-0.1.

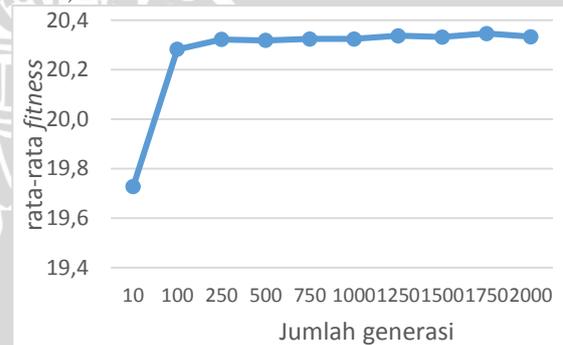


Gambar 14 Grafik Pengujian Partikel PTVPSO

Pada grafik Gambar 13 dapat dilihat bahwa range cLr berpengaruh terhadap perubahan nilai fitness. Semakin besar nilai epsilon cLr, maka semakin baik hasil regresinya sehingga menghasilkan nilai fitness yang semakin besar. Namun nilai fitness mulai stabil pada saat range cLr antara 0.00001 dan 0.1.

h. Pengujian Jumlah Generasi GA

Uji coba banyaknya jumlah Generasi GA yang paling optimal digunakan untuk mengetahui jumlah generasi yang paling optimal pada GA. Untuk pengujian jumlah generasi GA yang digunakan adalah 10, 100, 250, 500, 750, 1000, 1250, 1500, 1750, 2000.



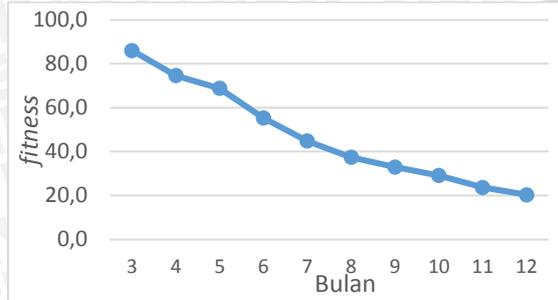
Gambar 15 Grafik Pengujian Generasi GA

Pada grafik Gambar 14 dapat dilihat bahwa jumlah generasi GA berpengaruh terhadap perubahan nilai fitness. Rata-rata nilai fitness yang paling besar didapatkan pada saat jumlah generasi sebanyak 1750 yaitu sebesar 20.346. Nilai fitness terendah terdapat pada jumlah generasi terendah. Hal ini disebabkan karena algoritma genetika belum dapat memproses secara optimal karena kurangnya jumlah generasi. Jumlah generasi yang terlalu banyak, akan menyebabkan waktu proses yang menjadi lebih lama dan hasil nilai fitness yang

dihasilkan juga belum tentu jauh lebih baik dari generasi yang lebih sedikit. Namun cenderung menunjukkan peningkatan nilai fitness karena memberikan eksplorasi terhadap ruang pencarian yang lebih besar [26].

i. Pengujian Jumlah Periode Prakiraan

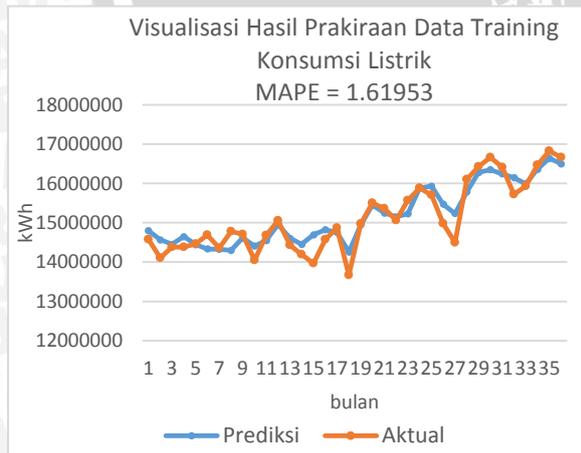
Pengujian periode prakiraan atau data etsting adalah oercobaan untuk mencari lama periode yang optimal untuk prakiraan. Untuk pengujian jumlah periode prakiraan yang digunakan adalah 3, 4, 5, 6, 7, 8, 9, 10, 11, dan 12 bulan.



Gambar 16 Grafik Pengujian Variasi Data Training Testing

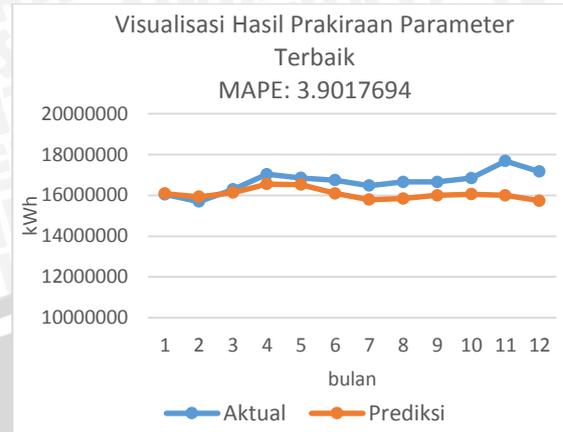
Pada grafik Gambar 15 dapat dilihat bahwa jumlah periode yang diprakiraan berpengaruh terhadap perubahan nilai fitness. Semakin besar jumlah periode yang diprakiraan nya, maka semakin kecil nilai fitnessnya. Ini membuktikan bahwa metode Support Vector Regression (SVR) tidak cocok untuk peramalan jangka jauh.

Berdasarkan parameter terbaik, menghasilkan grafik perbandingan nilai aktual dan hasil prediksi konsumsi listrik pada Gambar 16.



Gambar 17 Visualisasi Hasil Prakiraan Data Training Konsumsi Listrik

Sedangkan, untuk hasil prakiraan data testing menggunakan parameter terbaik ditunjukkan pada Gambar 17.



Gambar 18 Visualisasi Hasil Prakiraan Parameter Terbaik

7. PENUTUP

7.1 KESIMPULAN

Berikut adalah kesimpulan yang dapat diambil dari hasil yang telah didapatkan dari perancangan, implementasi dan pengujian yang telah dilakukan

1. Proses awal yang harus dilakukan dalam mengimplementasikan metode SVR dengan algoritma genetika untuk prakiraan kebutuhan listrik Kota Malang adalah menentukan data latih dan data uji yang akan digunakan, peramalan yang digunakan adalah peralaman dengan data secara sekuensial, untuk mendapatkan parameter yang optimal digunakan metode algoritma genetika ketika fase training, sedangkan untuk fase testing digunakan metode SVR tanpa algoritma genetika dengan menggunakan parameter yang optimal ketika fase training.
2. Untuk mengukur error rate dari solusi untuk permasalahan peramalan nilai tukar ini digunakan perhitungan nilai fitness yang didapatkan dari rata-rata nilai error dari prakiraan kebutuhan listrik itu sendiri. Berdasarkan pengujian yang telah dilakukan, dengan data training = 36 bulan, popSize = 40, iterasi = 1000, crossover rate = 0.1, mutation rate = 0.9, $\lambda = 0.01-10$, $\epsilon = 0.00000001-0.0001$, $C = 0.0001-0.1$, $cLr = 0.00001-0.1$, generasi = 1750, dan data testing = 3 bulan, nilai error terkecil didapatkan yaitu sebesar 0.161741..

7.2 SARAN

Untuk Berikut merupakan saran yang dapat digunakan untuk penelitian selanjutnya yaitu :

1. Untuk penelitian selanjutnya, peneliti dapat menambahkan meode kernel yang digunakan untuk mendapatkan hasil yang optimal. Misalnya, seperti kernel linier, kernel polinomial, kernel sigmoid, dan lain sebagainya.

2. Penambahan parameter algoritma genetika untuk diuji untuk hasil yang lebih optimal. Misalnya nilai minimum dan maksimum mutasi.
3. Penambahan penggunaan jumlah data latih dan data uji dan juga variasi percobaan.

DAFTAR PUSTAKA

- [1] Ahmed, H. & Glasgow, J., 2012. *Swarm Intelligence: Concepts, Models and Applications*. Ontario: School of Computing, Queen's University, Kingston.
- [2] Bagnasco, A., Fresi, F., Saviozzi, M., Silvestro, F., dkk., 2015. Electrical consumption forecasting in hospital facilities: An application case. *Energy and Buildings* 103 (2015) 261–270.
- [3] Escriva, G., Alvarez-bel, C., Roldan-blay, C., dkk., 2011. *New Artificial Neural Network Prediction Method for Electrical Consumption Forecasting Based on Building End-Uses*. Valencia: Institute for Energy Engineering, Universitat Politècnica de València, Camino de Vera.
- [4] Hsu, C., Chang, C. & Lin, C., 2010. *A Practical Guide to Support Vector Classification*. Taipei: Department of Computer Science National Taiwan University.
- [5] Jiang, L., Xiao, H., He J., dkk., 2015. Application of Genetic Algorithm to Pyrolysis of Typical Polymers. *Fuel Processing Technology* 138 (2015) 48–55.
- [6] Kaytez, F., Taplamacioglu, M., Cam, E. dkk., 2015. Forecasting Electricity Consumption: A Comparison Of Regression Analysis, Neural Networks and Least Squares Support Vector Machines. *Electrical Power and Energy Systems* 67 (2015) 431–438.
- [7] Kucharzyka, K., Crawford, R., Paszczynskia, A., dkk., 2012. Maximizing microbial degradation of perchlorate using a genetic algorithm: Media optimization. *Journal of Biotechnology* 157 (2012) 189– 197. Moscow: University of Idaho.
- [8] Kuo, B., Ho, H., Li, C., dkk., 2014. A Kernel-Based Feature Selection Method for SVM With RBF Kernel for Hyperspectral Image Classification. *Ieee Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 7, No. 1, January 2014.
- [9] Lu, X., Leng, Y., Xie, P., dkk., 2014. An Intelligent Task Scheduling Algorithm of Electricity Consumption for Reducing the Load Peak. *Proceeding of the 11th World Congress on Intelligent Control and Automation Shenyang, China, June 29 - July 4* 2014. Shanghai: School of Economics and Management, Shanghai University of Electric Power.
- [10] Mas'udia, P. dan Wardoyo R., 2012. Optimasi Cluster Pada Fuzzy C-Means Menggunakan Algoritma Genetika Untuk Menentukan Nilai Akhir. *IJCCS*, Vol.6, No.1, January 2012, pp. 101-110. Yogyakarta: Jurusan Ilmu Komputer dan Elektronika, FMIPA UGM.
- [11] Ogcu, G., Demirel, O. F. & Zaim, S., 2012. Forecasting Electricity Consumption with Neural Networks and Support Vector Regression. *Procedia - Social and Behavioral Sciences* 58 (2012) 1576 – 1585. Turkey: Department of Industrial Engineering, Fatih University.
- [12] Pasman, D. F., Muslim, M. A. & Dhofir M., 2010. Analisis Implementasi Jaringan Syaraf Adaptif untuk Peramalan Kebutuhan Energi Listrik Wilayah Malang. *Jurnal Nitro* Vol. 2, No. 2 April 2010. Malang: Teknik Elektro, Universitas Brawijaya
- [13] Pramesti, D., Mahmudy, W. & Indriati. 2015. Optimasi Komposisi Pakan Kambing Potong Menggunakan Algoritma Genetika. *DORO: Repository Jurnal Mahasiswa PTIHK Universitas Brawijaya*, vol. 5, no. 13. Malang.
- [14] Scholkopf, B. & Smola, A., 2004. *A tutorial on support vector regression*. *Statistics and Computing* 14: 199–222. Netherlands: Kluwer Academic Publishers.
- [15] Shukla, A., Pandey, H. & Mehrotra, D., 2015. Comparative Review of Selection Techniques in Genetic Algorithm. Noida: Amity University.
- [16] Suyanto, 2014. *Artificial Intelligence: Searching, Reasoning, Planning, Learning (Revisi Kedua)*. Penerbit: Informatika, Bandung
- [17] Vijayakumar S., & Wu, S., 1999. Sequential Support Vector Classifiers and Regression. *Proc. International Conference on Soft Computing (SOCO'99)*, Genoa, Italy, pp.610-619. Saitama: RIKEN Brain Science Institute, The Institute for Physical and Chemical Research, Hirosawa 2-1, Wako-shi
- [18] Wang, H. & Yang, S., 2013. Electricity Consumption Prediction Based on SVR with Ant Colony Optimization. *TELKOMNIKA*, Vol.11, No.11, November 2013, pp. 6928-6934. Anhui Hefei: School of Management of Hefei University of Technology.
- [19] Widodo, S., 2013. *Dasar dan pengukuran Listrik (Semester 1)*. [e-book] Kementerian Pendidikan dan Kebudayaan Republik

Indonesia. Tersedia di: <<http://bse.kemdikbud.go.id>> [Diakses 15 September 2015]

- [20] Yi-feng, J. & Shu-wen, W., 2010. Village Electrical Load Prediction by Genetic Algorithm and SVR. Wuhan: School of Electrical Engineering Wuhan University.
- [21] Lin, J., Shen P. & Wen, H., 2015. Repetitive Control Mechanism of Disturbance Cancellation Using a Hybrid Regression and Genetic Algorithm. *Mechanical Systems and Signal Processing* 62-63 (2015) 356–365. Taichung : Feng Chia University.
- [22] Alves, G. dan Silva, D., 2013. Data Envelopment Analysis for Selection of the Fitness Function in Evolutionary Algorithms Applied to Time Series Forecasting Problem. 2013 BRICS Congress on Computational Intelligence & 11th Brazilian Congress on Computational Intelligence. Brazil: Statistics and Informatics Department Federal Rural University of Pernambuco.
- [23] Priandani, N. D. & Mahmudy, W. F. 2015. Optimasi Travelling Salesman Problem with Time Windows (TSP-TW) pada Penjadwalan Paket Rute Wisata di Pulau Bali Menggunakan Algoritma Genetika. Seminar Nasional Sistem Informasi Indonesia. Malang: Jurusan Ilmu Komputer, Universitas Brawijaya.
- [24] Alfredo, Jondri & Rismala R., 2014. Prediksi Harga Saham menggunakan Support Vector Regression dan Firefly Algorithm. Bandung: Departemen Informatika, Universitas Telkom.
- [25] Mahmudy, W. F. 2013. Algoritma Evolusi. Malang: Program Teknologi Informasi dan Ilmu Komputer, Universitas Brawijaya.
- [26] Subanar & Permadi, I. 2010. Penerapan Algoritma Genetika untuk Optimasi Penjadwalan Tebangan Hutan (Applying of Genetic Algorithm for Scheduling Optimization Cuts Away Forest). *JUITA* Vol. I Nomor 1.

