

repository.ub.ac.id

PERAMALAN KONSUMSI AIR DI PDAM KOTA MALANG MENGGUNAKAN METODE SUPPORT VECTOR REGRESSION (SVR) DENGAN IMPROVE-PARTICLE SWARM OPTIMIZATION (IPSO)

Mega Manfaati¹⁾, Imam Cholissodin, S.Si.,M.Kom²⁾, Randy Cahya, S.ST, M.Kom³⁾

Program Studi Teknik Informatika

Fakultas Ilmu Komputer

Universitas Brawijaya, Malang 65145, Indonesia

email : megamanfaati21[at]gmail.com¹⁾, imam.cs[at]ub.ac.id²⁾, rendicahya[at]ub.ac.id³⁾

Abstrak

Air merupakan kebutuhan fundamental bagi kelangsungan hidup manusia. Semua makhluk hidup membutuhkan air di dalam melakukan aktifitas dan kegiatan sehari-hari. Manusia sangat bergantung dengan adanya sumber daya air. Badan penyedia dan produksi air Perusahaan Daerah Air Minum (PDAM) sudah didirikan di setiap Kota di Indonesia guna melayani kebutuhan air. Salah satunya adalah di Kota Malang. Banyak faktor yang mengakibatkan bertambahnya jumlah penduduk di Kota Malang yang otomatis akan mempengaruhi peningkatan kebutuhan konsumsi air penduduk Kota Malang. Banyak persoalan yang ada dan salah satunya adalah ketika jumlah air yang didistribusikan PDAM tidak sesuai dengan konsumsi penggunaan air yang mengakibatkan pemborosan air. Sebaliknya ketika yang didistribusikan tidak memenuhi konsumsi penduduk maka akan terjadi kurangnya air dari sisi konsumen tersebut. Oleh karena itu dengan melakukan peramalan konsumsi air ini diharapkan terjadi keseimbangan antara persediaan volume produksi untuk distribusi air dengan kebutuhan air konsumen. Cukup banyak metode peramalan yang sudah digunakan dengan sifat non linier dan menghasilkan peramalan yang cukup baik. Seperti penelitian "*Forecasting Agriculture Water Consumption Bases On PSO and SVM*" yang menghasilkan nilai MAPE sebesar 0.72. Kemudian untuk metode IPSO sendiri pernah digabungkan dengan metode SVR untuk meramalkan kesalahan pada proses *Tennessee Optimization* dan terbukti parameter IPSO menghasilkan tingkat error yang baik. Setelah melakukan pengujian dengan menggunakan data konsumsi air PDAM Kota Malang dengan rentang per bulan dari tahun 2008 sampai 2014, metode SVR yang dioptimasi menggunakan IPSO menghasilkan *Fitness* dengan nilai sebesar 0.719.

Kata Kunci : Air, Konsumsi Air, PDAM, SVR, IPSO, MAPE.

Abstract

*Water is a fundamental requirement for human survival. All human need water in the activity and daily activities. Humans are highly dependent on the existence of water resources. Agency providers and water production Regional Water Company (PDAM) has been set up in every town in Indonesia to serve the needs of the water. One is in the city of Malang. Many factors led to the increase of population in the city of Malang which will automatically affect the increase in water consumption needs of resident the city of Malang. Many problems that exist, and one of them is when the amount of water distributed taps are not in accordance with the consumption of water use that result in waste water. Otherwise when distributed does not meet the consumption of the population, there will be a lack of water on the consumer. Therefore, by forecasting water consumption is expected to occur the balance between supply production volume for the distribution of water to the water needs of consumer. A lot of forecasting methods that have been used with non-linear and generate a good forecasting. As the study "*Forecasting Agriculture Water Consumption Bases On PSO and SVM*" which produces MAPE value of 0,72. Then for IPSO method have been combined with SVR methods to forecast errors in the process and proven parameters *Tennessee Optimization* IPSO produce good error rate. After a test using water consumption with data PDAM Malang per month range from 2008 to 2014, SVR optimized mehod using IPSO generate fitness with a value of 0,719.*

Keywords : Water, Water Consumption, PDAM, SVR, IPSO, MAPE

1. PENDAHULUAN

Air merupakan kebutuhan makhluk hidup yang tidak dapat dipisahkan. Untuk kehidupan sehari-hari makhluk hidup menggunakan sumber daya air dalam melakukan berbagai aktifitas.

Perusahaan Daerah Air Minum (PDAM) merupakan badan yang menangani produksi air di Indonesia. PDAM sudah didirikan di setiap Kota, salah satunya di Malang. Malang merupakan kota yang berada dalam kawasan pegunungan dan memiliki iklim yang sejuk. Faktor-faktor inilah yang mengakibatkan meningkatnya jumlah penduduk karena banyaknya penduduk yang transmigrasi. Serta menjadi Kota pelajar. Seiring dengan hal tersebut kebutuhan konsumsi airpun juga meningkat.

Berdasarkan uraian singkat di atas PDAM harus meningkatkan kebutuhan air setiap tahunnya. Karena dari beberapa persoalan yang ada salah satunya adalah apabila jumlah air yang didistribusikan PDAM dan disalurkan lebih besar daripada permintaan akan konsumsi penggunaan air maka hal ini akan menunjukkan adanya pemborosan air atau inefisiensi produksi. Sedangkan apabila jumlah air yang didistribusikan PDAM lebih sedikit atau bahkan tidak memenuhi kebutuhan konsumsi air, maka pada sisi konsumen akan terjadi kekurangan air atau rendahnya produktifitas. Oleh karena itu dibutuhkan suatu estimasi untuk memperkirakan dengan tepat seberapa besar volume distribusi air PDAM di Kota Malang yang diperlukan untuk melayani kebutuhan air para konsumen PDAM Kota Malang di tahun tahun berikutnya. Maka penulis mengusulkan sistem peramalan tingkat konsumsi air di PDAM Kota Malang agar terjadi keseimbangan antara persediaan volume produksi untuk distribusi air dengan kebutuhan air pada konsumen.

Peramalan data time series adalah peramalan yang menggunakan data di masa lampau untuk meramalkan data di masa yang akan datang serta dikategorikan dalam bentuk linier dan non linier. Metode peramalan juga biasa disebut regresi.

Terdapat berbagai macam metode pengoptimalan yang mampu menyelesaikan permasalahan dengan hasil yang lebih baik. Penelitian mengenai peramalan air salah satunya dengan menggunakan metode PSO “*Forecasting Agriculture Water Consumption Based on PSO and SVM*”, mampu menghasilkan nilai optimal sebesar 0.72. kemudian pengembangan dari PSO itu sendiri yaitu IPSO dalam penelitian “*Fault Prediction Method Based on SVR of Improved PSO*” mampu mencapai nilai 0.05. di dalam penelitian tersebut membuktikan bahwa metode SVR-IPSO lebih baik dibandingkan dengan metode SVR-PSO.

Oleh karena itu, pada skripsi ini penulis mengusulkan peramalan konsumsi air di PDAM Kota Malang menggunakan metode *Support Vector Regression* (SVR) dengan *Improve Particle Swarm*

Optimization (IPSO). Implementasi yang akan dilakukan adalah menggabungkan metode peramalan SVR dengan metode IPSO sebagai pengoptimalan terhadap koefisien-koefisien yang ada di dalam SVR. Diharapkan kedua metode ini dapat menghasilkan nilai peramalan yang baik untuk konsumsi air.

2. DASAR TEORI

2.1 Air

Air merupakan unsur zat yang menjadi kebutuhan utama dalam kehidupan makhluk hidup. Permukaan bumi hampir mencapai 71% ditutupi oleh air. Air yang tersedia di bumi mencapai angka 1,4 triliun kubik. Air merupakan satu-satunya zat yang secara alami terbagi dalam 3 wujud.

Keperluan air sehari-hari di dalam kehidupan lingkungan atau rumah tangga ternyata memiliki jangkauan yang berbeda di setiap tingkatannya. Sehingga dapat diasumsikan bahwa apabila taraf kehidupan seseorang semakin tinggi maka kebutuhan seseorang akan air juga semakin bertambah. Kemudian jumlah penduduk bertambah maka otomatis kebutuhan air juga meningkat. Oleh karena itu terciptanya pihak PDAM dalam memenuhi dan menyesuaikan pemenuhan kebutuhan air untuk konsumen.

URAIAN	2011	2012	2013
Jumlah Pelanggan	106.044	116.184	125.614
Pemakaian Air Setahun	22.852.234	25.083.504	26.328.210
Pemakaian Air Rata-Rata Perbulan	1.904.353	2.090.292	2.194.01

Gambar 1 Tabel Jumlah Pemakaian Air Penduduk Malang

2.2 Support Vector Regression

SVR merupakan algoritma pengembangan dari SVM yang merupakan salah satu metode *machine learning* yang memiliki fitur yang baik dan akurasi yang tinggi serta optimal dalam menyelesaikan masalah. Berikut merupakan langkah – langkah metode sekuensial SVR^[23]:

- Pertama, inialisasi nilai parameter yang digunakan. Misal set $\lambda = 4.32$, $cLR = 0.08$, $C = 100$, $IterMax = 1000$ dan $\epsilon = 0.0004$.
- Kedua, set $\alpha_i = \alpha_i^* = 0$, lalu hitung matriks R_{ij} .
- $R_{ij} = (K(x_i, x_j) + \lambda^2)$ dan $i, j = 1, \dots, l, \dots, l$ (1) l adalah banyaknya data.

- Ketiga, lakukan (a), (b) dan (c) berikut dengan $i=1$ sampai N .
- (a) $E_i = y_i - \sum_{j=1}^l (\alpha_j^* - \alpha_j) R_{ij} \dots \dots \dots (2)$
- (b) $\delta \alpha_i^* = \min\{\max[\gamma(E_i - \varepsilon), -\alpha_i^*], C - \alpha_i^*\} \dots \dots \dots (3)$
- $\delta \alpha_i = \min\{\max[\gamma(-E_i - \varepsilon), -\alpha_i], C - \alpha_i\} \dots \dots \dots (4)$
- (c) $\alpha_i = \alpha_i + \delta \alpha_i \dots \dots \dots (5)$
- $\alpha_i^* = \alpha_i^* + \delta \alpha_i^* \dots \dots \dots (6)$
- $\delta \alpha_i^*$ dan $\delta \alpha_i$ merupakan variabel tunggal, bukan bentuk dari perkalian δ dan α_i^* atau perkalian δ dan α_i .
- Kembali ke langkah Ketiga, sampai pada kondisi IterMax atau $\max(|\delta \alpha_i|) < \varepsilon$ dan $\max(|\delta \alpha_i^*|) < \varepsilon$.
- Fungsi regresinya adalah $f(x) = \sum_{j=1}^l (\alpha_j^* - \alpha_j) (K(x_i, x_j) + \lambda^2) \dots \dots \dots (7)$
- 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*.
- $\delta \alpha_i^*$ = merupakan variabel *slack*.
- $\delta \alpha_i$ = merupakan variabel *slack*.
- α_i, α_i^* = merupakan suatu nilai formulasi.
- C = merupakan nilai kompleksitas.
- ε = merupakan nilai deviasi
- λ = variabel *lambda*
- x_i = merupakan data ke- i
- x_j = merupakan data

2.3 Particle Swarm Optimization

PSO merupakan algoritma yang diinspirasi oleh tingkah laku sosial sekawanan burung atau ikan. Misalnya ada sekawanan burung atau ikan yang mencari makanan secara random pada suatu daerah^{[16][22]}, dimana hanya ada sebuah makanan di daerah tersebut dan sekawanan burung atau ikan tersebut tidak tahu dimana keberadaan makanan tersebut. Namun mereka tahu makanan pada setiap iterasi, sehingga strategi yang dapat digunakan oleh mereka adalah mencari makanan dengan mengikuti burung yang keberadaannya lebih dekat dengan makanan tersebut^[10].

Adapun langkah – langkah algoritma PSO adalah sebagai berikut^[13]:

1. Inisialisasi secara acak n posisi vector $\{x_k = 1, 2, \dots, n\}$ dengan masing – masing sebesar m partikel (tergantung dengan permasalahan yang akan diselesaikan).
2. Inisialisasi secara acak n velocity $\{v_k, k = 1, 2, \dots, n\}$ dengan distribusi minimum dan maksimum.
3. Evaluasi masing – masing nilai *fitness* untuk tiap partikel sesuai dengan fungsi yang sudah ditentukan sebelumnya Fit_i .

4. Untuk tiap partikel, lakukan perbandingan *fitness value* dengan partikel *global best* P_g
5. Hitung kecepatan dan perbarui posisi dari masing – masing partikel
6. Untuk tiap partikel, lakukan perbandingan *fitness value* dengan partikel *global best* P_g .
7. Jika $Fit_i > P_g$, maka perbarui dan simpan nilai Fit_i sebagai P_g yang baru.
8. Melakukan pembaruan terhadap posisi dan kecepatan tiap partikel
9. Melakukan evaluasi fungsi *fitness*
10. Melakukan pembaruan P_g dan P_i .
11. Proses 3 hingga 8 akan selalu berulang hingga mencapai kriteria pemberhentian yang sudah ditetapkan
12. Memperbarui partikel terbaik dan yang terakhir yaitu menemukan solusi pada partikel terbaik tersebut

2.4 Improve Particle Swarm Optimization

IPSO merupakan pengembangan dari algoritma PSO dalam rangka mencegah konvergensi dini. Berikut langkah-langkah dasar dari algoritma IPSO

...

1. Inisialisasi kelompok partikel secara acak
2. Lakukan pembaruan setiap kecepatan dan posisi
3. Kondisi apakah partikel baru diterima atau tidak bergantung pada hasil seleksi
4. Ulangi iterasi hingga mencapai kondisi pemberhentian

Langkah-langkah di atas sama halnya dengan proses yang ada dalam PSO namun di dalam metode IPSO perbedaan terletak pada penambahan koefisien λ yang menjadi faktor konvergensi yang diletakkan di depan inersia

weight (w) dimana kondisi $\lambda = \sin^3 \alpha$ dengan $\alpha = [0, \pi/8]$. Sehingga untuk melakukan update kecepatan dan posisi dengan improvisasi

dijabarkan dalam persamaan berikut :

$$v_{il} = \lambda w v_{il} + s_1 \times rand \times (p_{il} - x_{il}) + s_2 \times rand \times (p_{gl} - x_{il})$$

$$x_{il} = x_{il} + \lambda w_1 v_{il} \dots \dots \dots (1)$$

Keterangan rumus :

- w = *inertia weight* (fungsi pemberat)
- V_{id} = Kecepatan
- c = faktor pemberat
- P_{id} = partikel posisi
- P_{gd} = *global best*
- x = posisi terakhir i pada iterasi tersebut

Karena nilai velocity yang masalahnya adalah cenderung terjebak pada optimum lokal, maka diperlukan tambahan nilai bobot inerti dalam rangka meningkatkan performansi pada PSO.

Berikut dijelaskan pada Persamaan:

$$w = w_{\min} + (w_{\max} - w_{\min}) \frac{(t_{\max} - t)}{t_{\max}}$$

Keterangan Rumus :

t_{\max} : Iterasi maksimum yang sebelum melakukan training IPSO telah diinisialisasi.

t : Merupakan iterasi yang sedang berjalan, yaitu iterasi 1 sampai n .

w_{\min} : Bobot minimum untuk membatasi w yang akan diolah .

w_{\max} : Bobot maksimum untuk membatasi w yang akan diolah.

2.5 Normalisasi Data dan Denormalisasi Data

Dalam melakukan proses perhitungan dalam peramalan nilai tukar ini, perlu dilakukan proses *preprocessing* terlebih dahulu. Proses *preprocessing* data tersebut berupa normalisasi data. Hal ini bertujuan untuk standarisasi semua data yang digunakan dalam perhitungan sehingga data berada pada jarak tertentu^[17]. Proses normalisasi yang digunakan pada penelitian ini adalah *Min-Max normalization*. Perhitungan *Min-Max normalization* ditunjukkan pada Persamaan 14:

$$x' = \frac{(x - x_{\min})}{x_{\max} - x_{\min}} \dots \dots \dots (14)$$

Sedangkan untuk proses denormalisasi data adalah proses untuk mengembalikan nilai data menjadi nilai riil (seperti keadaan sebelum dinormalisasi) yaitu dengan mencari nilai x . Proses pencarian nilai x dapat dijabarkan melalui Persamaan 15, dimana Persamaan 14 didapat melalui *reverse* dari Persamaan 15

$$x = (x' \times (x_{\max} - x_{\min})) + x_{\min} \dots \dots \dots (15)$$

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.

2.6 Nilai Evaluasi

Nilai evaluasi yang digunakan adalah *Mean Absolute Percentage Error (MAPE)*, dimana MAPE memberikan indikasi seberapa besar prosentase kesalahan dalam meramal dibandingkan dengan nilai aktual. Penjabaran rumus MAPE akan dijelaskan pada Persamaan 16^[12].

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \dots \dots \dots (16)$$

Sedangkan penjabaran rumus dari nilai *fitness* ditunjukkan pada Persamaan 17^[21]

$$Fitness = \frac{1}{1 + MAPE} \dots \dots \dots (17)$$

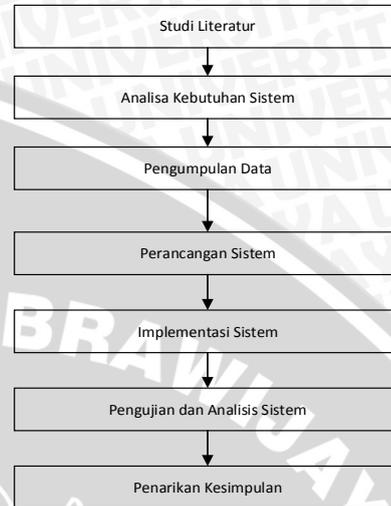
Keterangan:

\hat{y}_i = Nilai hasil ramalan

y_i = Nilai aktual

3. METODOLOGI PENELITIAN

Tahapan penelitian ini ditunjukkan pada Gambar 2. Diagram Alir Metode Penelitian seperti ditunjukkan pada Gambar 2:



Gambar 2 Diagram Alir Tahapan Penelitian

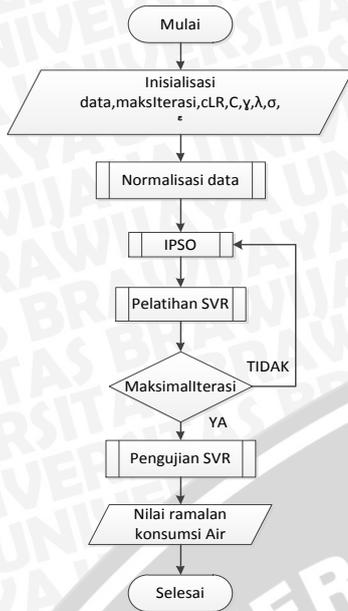
3.1 Data Penelitian

Dalam penelitian ini sistem yang dibuat bertujuan untuk melakukan peramalan terhadap konsumsi air di PDAM Kota Malang. Objek yang digunakan atau data yang di inputkan adalah data konsumsi air penduduk Kota Malang dalam rentang per bulan dari tahun 2008-2014 se Kabupaten Malang.

4. PERANCANGAN SISTEM

Peramalan konsumsi air dilakukan dengan membentuk model regresi. Kemudian setelah itu diuji untuk mendapatkan nilai *fitness* dan *error rate*. Tahap pertama yang dilakukan adalah menginisialisasi parameter SVR, setelah itu melakukan normalisasi data. Setelah melakukan proses normalisasi, IPSO berperan sebagai metode optimasi yang menghasilkan parameter-parameter yang nantinya akan digunakan di dalam SVR. Setelah mencapai iterasi yang maksimal maka didapatkanlah partikel terbaik yang akan digunakan di dalam peramalan. Partikel yang terbaik itulah yang nantinya akan digunakan untuk meramalkan data *testing* sehingga diperoleh hasil peramalan. Diagram alir proses umum akan dijelaskan pada Gambar 3.





Gambar 3 Diagram Alir Proses SVR-IPSO

Step 1:

Inisialisasi data yang akan diolah, parameter SVR, dan parameter IPSO.

Step 2:

Normalisasi data menggunakan *min-max normalization*.

Step 3:

Inisialisasi partikel IPSO.

Step 4:

Lakukan pembaruan terhadap kecepatan dan posisi.

Step 5:

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

Step 6:

Perbarui *pbest* dan *gbest*.

Step 7:

Setelah IPSO mencapai iterasi maksimum, gunakan nilai *gbest* untuk melakukan *testing* pada SVR.

Step 8:

Lakukan perhitungan *error* setelah mendapatkan hasil peramalan.

5. IMPLEMENTASI

5.1 Halaman Home

Pada halaman awal ini user akan diberi 2 pilihan button proses yaitu button proses untuk fase *training* dan button proses untuk fase *testing*. Halaman *training* data dapat dilihat pada **Error! Reference source not found.**



Gambar 4 Halaman Home

5.2 Halaman Fase Training Data

Pada halaman fase *training* data ini user dapat memasukkan nilai parameter yang telah disediakan yaitu mulai dari jumlah partikel, jumlah iterasi IPSO, jumlah iterasi SVR, panjang data training dan panjang fitur data. Di bawah terdapat button OK yang akan membawa user pada halaman *result* Halaman *training* data dapat dilihat pada **Error! Reference source not found.**



Gambar 5 Halaman Fase Training

5.3 Halaman Result Training Data

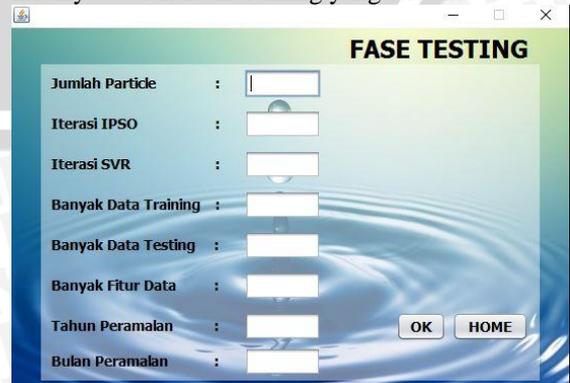
Pada halaman *result training* data ini akan menampilkan hasil dari training yang telah dilakukan. Halaman akan menampilkan hasil nilai *fitness* terbaik di generasi ke n dan di partikel ke n



Gambar 6 Halaman result training

5.4 Halaman Fase Testing

pada halaman ini user akan memasukkan kombinasi nilai variabel testing dimana default nilainya adalah hasil training yang terbaik.



Gambar 7 Halaman Fase Testing



5.5 Halaman *Result Testing*

Pada halaman ini adalah hasil dari fase testing yang telah dilakukan. Disini akan terdapat result yang menunjukkan hasil peramalannya.

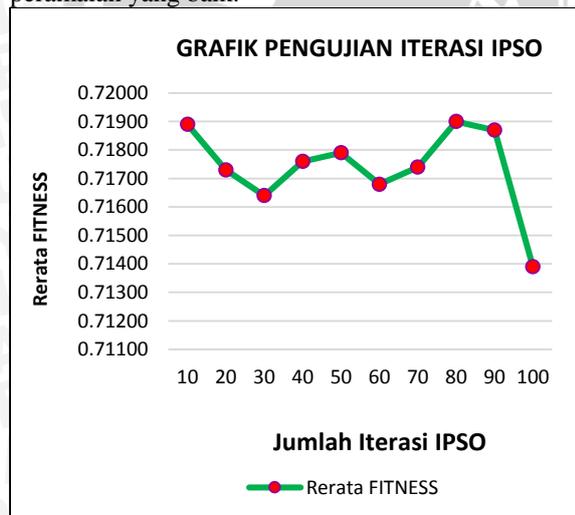


Gambar 8 Halaman Result Testing

6. PENGUJIAN DAN ANALISIS

a. Pengujian Jumlah Iterasi IPSO

Pengujian jumlah iterasi IPSO ini dilakukan dengan iterasi maksimal 100. Pengujian ini dilakukan untuk mengetahui jumlah iterasi paling optimal pada IPSO untuk memberikan hasil peramalan yang baik.

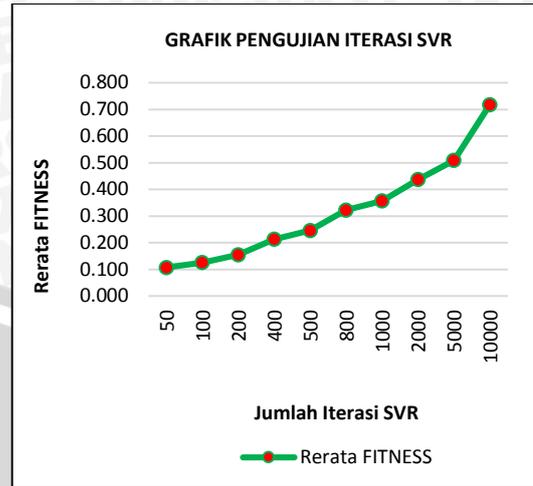


Gambar 4 Grafik Hasil Pengujian Iterasi IPSO

Berdasarkan hasil grafik uji coba jumlah iterasi IPSO pada Gambar 6.1 yaitu Grafik Pengujian Iterasi IPSO. Rata-rata nilai fitness terbesar diperoleh dari jumlah iterasi ke 80. Pada iterasi ke 80 nilai fitness yang dihasilkan sebesar 0.72, hasil nilai fitness dalam uji coba iterasi IPSO ini sangat bervariasi. Oleh karena itu, berdasarkan analisa hasil uji coba pada gambar 6.1 Grafik Pengujian Iterasi IPSO ini dapat disimpulkan bahwa semakin banyak jumlah iterasi IPSO belum tentu semakin baik nilai fitness yang didapatkan.

b. Pengujian Jumlah Iterasi SVR

Uji coba jumlah iterasi SVR ini semakin banyak jumlah iterasi maka hasilnya akan semakin baik.

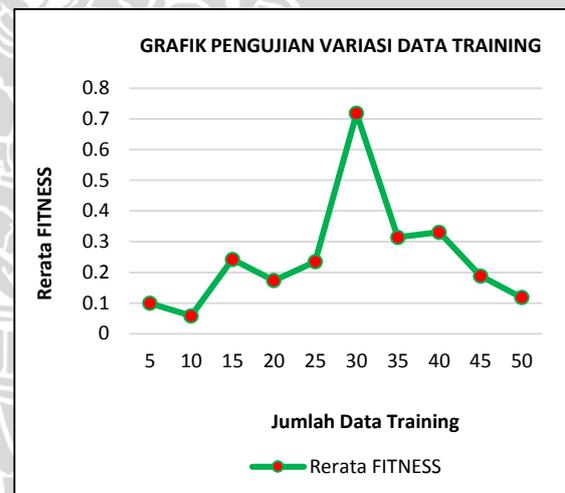


Gambar 5 Grafik Pengujian Jumlah Iterasi SVR

Berdasarkan Gambar 7 grafik hasil pengujian jumlah iterasi SVR rata-rata nilai fitness terbesar didapatkan pada iterasi ke 10000 dengan nilai fitness sebesar 0,717.

c. Pengujian Jumlah Data Training

Pada uji coba banyak jumlah data training yang ideal adalah data training dengan jumlah 30 data training.

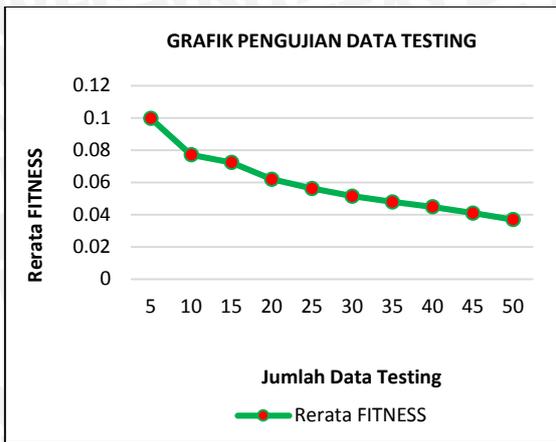


Gambar 8 Grafik Pengujian Jumlah Data Training

Berdasarkan Gambar 8 Grafik pengujian Jumlah Data Training dapat disimpulkan bahwa jumlah data training yang ideal yaitu sebanyak 30. Hal ini dipengaruhi oleh karakteristik data. Semakin data bervariasi maka semakin baik nilai fitness yang akan dihasilkan.

d. Pengujian Jumlah Data Testing

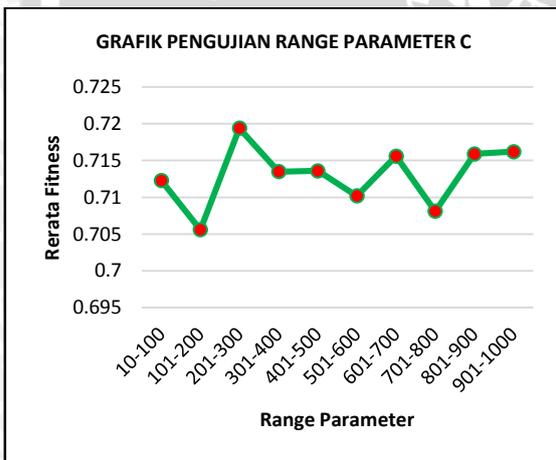
Berdasarkan hasil Gambar 9 Grafik pengujian jumlah data testing disimpulkan bahwa jumlah data testing yang ideal adalah 5.



Gambar 9 Grafik Pengujian Jumlah Data Testing

e. Pengujian Range Parameter C

Pengujian ini dilakukan bertujuan untuk menentukan batas pencarian parameter C yang optimal dan terbaik dalam peramalan. Pengujian pada parameter C ini yang digunakan adalah 10-100, 101-200, 201-300, 301-400, 401-500, 501-600, 601-700, 701-800, 801-900, 901-1000.

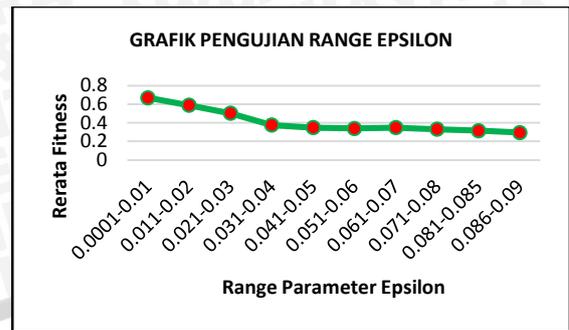


Gambar 10 Grafik Pengujian Range Parameter C

Berdasarkan Grafik hasil pengujian range parameter di atas menunjukkan nilai *fitness* terbesar dihasilkan pada range 201-300. Dengan nilai mencapai 0,72.

f. Pengujian Range Parameter ε

Pengujian ini dilakukan untuk menemukan batas pencarian parameter ε paling optimal untuk menghasilkan solusi terbaik di dalam peramalan. Pengujian dilakukan sebanyak 10 kali.

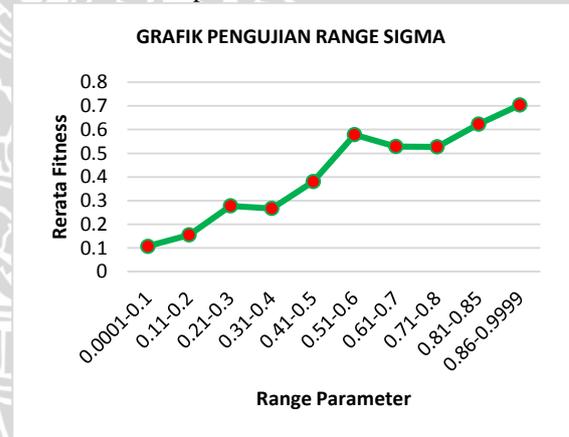


Gambar 10 Grafik Pengujian Range Epsilon

Berdasarkan Gambar 10 Grafik pengujian range epsilon menunjukkan bahwa pada range 0,0001-0,01 menghasilkan nilai *fitness* terbesar yaitu 0,6702. Hasil ini menunjukkan batas nilai parameter yang paling optimal ada dalam range tersebut. Hasil ini menyimpulkan bahwa semakin kecil batas range epsilon akan menghasilkan nilai *fitness* terbaik untuk peramalan. Hal ini ditunjukkan dengan pola grafik yang semakin besar polanya semakin turun.

g. Pengujian Range Parameter σ

Uji coba range parameter sigma ini dilakukan untuk menemukan batas pencarian parameter sigma yang palin optimal dalam meenghasilkan solusi terbaik di dalam peramalan.



Gambar 11 Grafik Pengujian Range Parameter Sigma

Berdasarkan grafik nilai *fitness* terbesar diperoleh pada batas 0,86-0,9999. Grafik menunjukkan bahwa semakin besar range yang digunakan maka hasil nilai *fitness* yang dihasilkan juga semakin besar yaitu mencapai nilai 0,703. Sigma sangat berperan penting dalam menentukan simpangan data yang sangat berpengaruh dalam peramalan.

7. PENUTUP

7.1 KESIMPULAN

Berikut hasil kesimpulan dari penelitian mengenai peramalan konsumsi air di PDAM Kota Malang menggunakan metode *Support Vector Regression* dengan *Improve Particle Swarm Optimization* :

1. Algoritma *Improve Particle Swarm Optimization* dapat diimplementasikan untuk optimasi peramalan konsumsi air di PDAM Kota Malang menggunakan metode *Support Vector Regression* (SVR) dengan menemukan koefisien-koefisien terbaik untuk setiap parameter SVR yang dioptimasi. Adapun koefisien terbaik yang diperoleh dalam penelitian ini yaitu :

- nilai Kompleksitas (C) yang terletak pada range [201-300]
- nilai Epsilon (ϵ) yang terletak pada range [0.0001-0.1]
- nilai Sigma (σ) yang terletak pada range [0.86-0.9999]

2. Tabulasi data yang digunakan dalam SVR adalah sebanyak 30 data yang terdiri dari data konsumsi air di PDAM Kota Malang dalam rentang waktu perbulan, dengan panjang fitur data sebanyak 6 fitur. Pada sistem ini algoritma *Improve Particle Swarm Optimization* dalam mengoptimasi peramalan konsumsi air di PDAM Kota Malang menggunakan metode *Support Vector Regression* menghasilkan tingkat akurasi nilai *fitness* sebesar 0.719.

7.2 SARAN

Pada penelitian selanjutnya dapat menambahkan penggunaan peramalan data konsumsi air dengan menggunakan analisis fundamental karena analisis fundamental memiliki faktor-faktor yang mempengaruhi data konsumsi air sebagai fitur peramalan. Serta pada penelitian selanjutnya dapat menggunakan penambahan *Time Varying Acceleration Coefficients* (TVAC) untuk lebih menyeimbangkan eksplorasi global dan eksploitasi local.

DAFTAR PUSTAKA

- [1] Lu S., Cai Z., Zhang X., 2009. *Forecasting Agriculture Water Consumption Based on PSO and SVM*. School of Computer Science and Information Engineering Chongqing Technology and Business University Chongqing, China.
- [2] Zou, J., Li, C., Yang, Q., 2015. *Fault Prediction Method based on SVR of Improved PSO*. School of Information Science and Engineering, Shenyang Ligong University, Shenyang 110159, China.
- [3] Supijatno., Chozin Ah., Sopandie Di., Tri., Junaedi A., Lubis I., 2012. *Water Consumption Evaluation among Rice Genotypes Showing Possibility to Explore Benefit of Water Use Efficiency*. Departemen Agronomi dan Hortikultura, Fakultas Pertanian, Institut Pertanian Bogor. 5 Januari 2012.
- [4] Wachjar A., Angga R., 2013. *Productivity Increase and Water Consumption Efficiency of Amaranth (Amaranthus tricolor L.) in Hydroponic Technique by Plant Population Arrangement*. Departemen Agronomi dan Hortikultura, Fakultas Pertanian, Institut Pertanian Bogor.
- [5] Briawan D., Rachma P., Annisa K., 2011. *Kebiasaan Konsumsi Minuman Dan Asupan Cairan Pada Anak Usia Sekolah Di Perkotaan*. Departemen Gizi Masyarakat, Fakultas Ekologi Manusia, Institut Pertanian Bogor 16680.
- [6] Sutarno., 2010. *Analisis Perbandingan Transformasi Wavelet pada Pengenalan Citra Wajah*. Fakultas Ilmu Komputer, Universitas Sriwijaya, Vol.5 No.2 Juli 2010.
- [7] Ratnawera, A., Saman, K., Halgamuge., 2004. *Self-Organizing Hierarchical Particle Swarm Optimizer With Time-Varying Acceleration Coefficients*. IEEE Transactions On Evolutionary Computation, Vol. 8, No. 3, June 2004.
- [8] Kinoshita, K., Watanabe, K., Isshiki., M., 2014. *Estimation of Inverse Model Based on ANN and PSO with Adaptively Varying Acceleration Coefficients*. SICE Annual Conference 2014 September 9-12, 2014, Hokkaido University, Sapporo, Japan.
- [9] Liu, B.X., Wu, Y., Xu, X., dkk., 2014. *Chaos Adaptive Improved Particle Swarm Algorithm for Solving Multi-Objective Optimization*. TELKOMNIKA Indonesian Journal of Electrical Engineering Vol.12, No.1, January 2014, pp. 703 – 710.
- [10] Wang, Li., Zhao., Qi, Liu L., *The Application of BP Neural Network Based on Improved PSO in BF Temperature Forecast*.
- [11] Ilka, R., Gholamian S.A., 2012. *Optimum Design of a Five-phase PMSM for Underwater Vehicles by use of PSO*. TELKOMNIKA Indonesian Journal of Electrical Engineering Vol.10, No.5, September 2012, pp. 925 – 932.
- [12] Wang, F., Tan, G., Deng, Z., dkk., 2008. *Real-time Traffic Flow Forecasting Model and Parameter Selection based on ϵ -SVR*. Proceedings of the 7th World Congress on Intelligent Control and Automation June 25 - 27, 2008, Chongqing, China.
- [13] Ling W., Mei Fu., 2009. *A Novel Approach Using SVR Ensembles for Minor Prototypes Prediction of Seawater Corrosion Rate*. Automation department, Information Engineering School University of Science and Technology Beijing, China.
- [14] Iza R, Aswin M, Mustofa A., 2013 *Steganografi Pada Citra Digital Menggunakan Metode Discrete Wavelet Transform*, Jurusan Teknik elektro Fakultas Teknik Universitas Brawijaya. Malang, Indonesia.

- [15] Sutarno., 2010. *Analisis Perbandingan Transformasi Wavelet pada Pengenalan Citra Wajah*. Fakultas Ilmu Komputer, Universitas Sriwijaya. Vol.5, No.2, Juli 2010.
- [16] Vijayakumar, S., Wu S., 1999. Sequential Support Vector Classifiers and Regression. RIKEN Brain Science Institute 1999, pp.610 – 619.
- [17] Rajkumar, N., Jaganathan., P., 2013. *A New RBF Kernel Based Learning Method Applied to Multiclass Dermatology Diseases Classification*. Proceedings of 2013 IEEE Conference on Information and Communication Technologies (ICT 2013).
- [18] Putri R, Dewi C, Indriati.,2013, *Implementasi Algoritma Particle Swarm Optimization Untuk Optimasi Fungsi Keanggotaan Pada Kondisi Penderita Penyakit Hepatitis*. Program Studi Ilmu Komputer, Jurusan Ilmu Komputer Fakultas Program Teknologi Informasi dan Ilmu Komputer Jl. Veteran No 8, Malang 65145, Indonesia.
- [19] Qing Y, Jian-qiao, Chang L., Nian L., 2013 Real-Time fault diagnosis approach based on lifting wavelet and recursive incremental clustering. System Engineering and Electronics, China. Vol.35, No.1 January 2013.

