

Prediksi Penerimaan Zakat menggunakan Metode Support Vector Regression (SVR) dengan Flower Pollination Algorithm (FPA)

Tusiarti Handayani¹, Imam Cholissodin², Agus Wahyu Widodo³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹135150201111078@mail.ub.ac.id, ²imamcs@ub.ac.id, ³a_wahyu_w@ub.ac.id

Abstrak

Pembayaran dan penyaluran zakat di Indonesia dikelola oleh Badan Amil Zakat, salah satunya adalah Lembaga Amil Zakat Infaq dan Shadaqah Muhammadiyah (LAZISMU) Malang. Fluktuasi tinggi rendahnya dana zakat yang diterima oleh LAZISMU Malang mempengaruhi banyaknya dana zakat yang bisa disalurkan kepada masyarakat di seluruh wilayah Malang. Prediksi penerimaan zakat sangat diperlukan untuk mengetahui jumlah zakat yang akan diterima, sehinggaantisipasi solusi ketika dana kurang dari target penyaluran dapat dilakukan sedini mungkin. Prediksi yang dilakukan pada penelitian ini adalah menggunakan metode *Support Vector Regression* (SVR) dengan *Flower Pollination Algorithm* (FPA). SVR digunakan untuk melakukan prediksi penerimaan zakat berdasarkan data *history* penerimaan zakat, kemudian FPA digunakan untuk melakukan optimasi nilai dari parameter yang akan digunakan pada metode SVR. Data yang digunakan sebanyak 64 data historis dari bulan Juli 2011 – Oktober 2016, data penerimaan zakat dari salah satu Lembaga Amil Zakat Nasional wilayah Malang yaitu LAZISMU Malang. Hasil pengujian yang dilakukan terhadap prediksi penerimaan zakat menggunakan SVR dengan FPA pada data penerimaan zakat dari tahun 2011 hingga 2016 menghasilkan nilai sebesar 0.2497 dalam *fitness* atau 3.0048 dalam MAPE yang berarti rata-rata selisih antara data aktual dengan hasil prediksi adalah senilai Rp144.741.

Kata Kunci: penerimaan zakat, zakat, SVR, FPA, MAPE.

Abstract

Payment and distribution of zakat in Indonesia managed by Badan Amil Zakat, which of one is Lembaga Amil Zakat Infaq and Shadaqah Muhammadiyah (LAZISMU) Malang. Fluctuations in the level of zakat fund received by LAZISMU Malang affect in the amount of zakat fund that can be distributed to communities in the all of Malang region. Zakat reception forecasting is so needed to determined the amount of zakat received, so that solution anticipation when the fund is less than the distribution target can be done as early as possible. Prediction are made on this research is using Support Vector Regression (SVR) with Flower Pollination Algorithm (FPA) method. SVR used to make prediction of zakat received based on historical data zakat received, and then FPA used to make optimization value from parameter to be used on SVR method. Data used as many as 64 historical data from Juli 2011 up to Oktober 2016 data received of zakat for the one of Lembaga Amil Zakat Nasional at Malang region that is LAZISMU Malang. The results of tests performed on the prediction zakat using SVR with FPA on zakat revenue data from 2011 to 2016 resulted value of 0.2497 in the fitness and 3.0048 in the MAPE which means average difference between of actual data and predict result is Rp144.741.

Keywords: zakat revenue, zakat, SVR, FPA, MAPE.

1. PENDAHULUAN

Pengelola zakat di Indonesia diatur dalam Undang-Undang No. 38 tahun 1999 yang berisi “Badan Amil Zakat adalah lembaga pengelola zakat yang terdiri atas masyarakat dengan tugas

yaitu mengumpulkan, mendistribusikan, dan mendayagunakan serta bertanggungjawab kepada pemerintah sesuai dengan tingkatnya”. Salah satu Badan Amil Zakat yang ada di Kota Malang adalah Lembaga Amil Zakat Infaq dan Shadaqah Muhammadiyah (LAZISMU) Malang.

Fluktuasi tinggi rendah dana zakat yang diterima oleh lembaga LAZISMU mempengaruhi jumlah dana zakat yang bisa disalurkan kepada calon penerima zakat. Solusi yang saat ini dilakukan ketika jumlah yang diterima kurang dari target distribusi kepada calon penerima zakat adalah dengan melakukan seleksi ulang kepada calon penerima zakat.

Prediksi penerimaan zakat sangat diperlukan untuk mengetahui jumlah zakat yang akan diterima, sehinggaantisipasi solusi ketika dana kurang dari target penyaluran bisa dilakukan sedini mungkin. Beberapa metode yang dapat digunakan untuk melakukan prediksi, sebagai contohnya adalah *Support Vector Regression* (SVR) dan *Artificial Network Neural* (ANN). SVR terbukti sebagai salah satu metode prediksi yang memberikan hasil jauh lebih baik dibandingkan dengan yang lainnya. Hal ini didukung oleh penelitian yang dilakukan oleh Anandhi, dkk. (2013) dengan menggunakan metode SVR untuk menyelesaikan kasus prediksi permintaan dan pasokan kayu, menghasilkan nilai *Mean Magnitude Relative Error* (MMRE) yang cukup rendah yakni 0.400824. Penelitian prediksi waktu perjalanan dengan SVR menghasilkan nilai *Relative Mean Error* (RME) sebesar 3.91% (Hsin Wu, dkk., 2015). SVR memiliki kelemahan yaitu ketidakmampuan SVR dalam menemukan kombinasi koefisien parameter yang mampu memberikan hasil yang optimal, sehingga diperlukan metode optimasi untuk memudahkan SVR dalam menemukan kombinasi koefisien parameternya (Alfredo et al., Telkom Bandung).

Metode optimasi untuk mengoptimalkan hasil prediksi terdapat beberapa macam, sebagai contohnya: *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO), *Flower Pollination Algorithm* (FPA) dan *Artificial Bee Colony* (ABC). Optimasi dengan menggunakan algoritma *Flower Pollination Algorithm* (FPA) terbukti mampu memberikan hasil yang lebih baik dibandingkan dengan algoritma optimasi yang lainnya. Pernyataan ini didukung dengan penelitian yang dilakukan oleh Chiroma, dkk. (2016) dengan membandingkan hasil dari kasus prediksi konsumsi minyak tanah menggunakan algoritma FPA, GA, PSO, dan ABC. Dari penelitian tersebut FPA memberikan hasil yang jauh lebih baik dibandingkan yang lainnya, menghasilkan nilai MSE sebesar 0.000397.

Berdasarkan penjabaran diatas, implementasi prediksi zakat yang akan dilakukan pada penelitian ini adalah

menggunakan *Support Vector Regression* (SVR) dengan *Flower Pollination Algorithm* (FPA). Diharapkan dengan dilakukan penelitian ini bisa memberikan hasil prediksi untuk jangka waktu terdekat sesuai dengan data uji yang digunakan.

2. TINJAUAN PUSTAKA

2.1 Zakat

Definisi zakat berdasarkan Undang-Undang Pengelolaan Zakat, Zakat adalah sebagian harta yang wajib dikeluarkan oleh seorang muslim yang untuk disalurkan kepada yang berhak menerima sesuai dengan ketentuan dan syariat Islam. Zakat dibedakan atas 2 jenis yaitu zakat fitrah atau nafs dan zakat maal atau zakat harta. Zakat fitrah adalah zakat yang sifatnya wajib dikeluarkan oleh muslim yang mempunyai kelebihan persediaan makanan untuk digunakan pada hari raya umat Islam dengan beberapa ukuran pemberian dan beberapa aturan penerima, sedangkan zakat maal adalah kewajiban zakat yang harus dikeluarkan oleh seseorang sesuai dengan harta yang dimiliki dengan aturan pengeluaran yang telah ditentukan dan penerima yang telah diatur dalam syariat Islam (Purbasari, 2015).

2.2 Support Vector Regression (SVR)

SVR merupakan pengembangan model regresi dari SVM. SVR memetakan data secara *non-linear* ke dimensi yang lebih tinggi dengan tujuan dapat menerima regresi *linear*. Algoritma sekuensial adalah salah satu metode untuk regresi *non-linear* yang mampu memberikan solusi optimal, iterasi lebih cepat, dan urutan yang lebih tepat dibandingkan dengan metode konvensional (Vijayakumar & Wu, 1999). Berikut adalah tahapan Algoritma Sekuensial untuk regresi non linier:

1. Inisialisasi parameter yaitu variabel skalar (λ), *learning rate* (γ), variabel slack (C), epsilon (\mathcal{E}) dan iterasi maksimum.
2. Inisialisasi α_i^* dan α_i dengan nilai awal 0 untuk keduanya, dilanjutkan dengan menghitung nilai Matriks Hessian.

$$R_{ij} = (K(x_i, x) + \lambda^2)$$
 untuk $i, j = 1, \dots, l$ (1)
3. Lakukan iterasi untuk setiap titik data pelatihan sesuai dengan langkah a, b dan c.
 - a. Lakukan pada setiap data latih dengan persamaan berikut:

$$E_i = y_i - \sum_{j=1}^l (\alpha_j^* - \alpha_j) R_{ij} \quad (2)$$

- b. Lakukan pada setiap data latih dengan persamaan berikut:

$$\delta\alpha_i^* = \min \{ \max[\gamma(E_i - \varepsilon), -\alpha_i^*], C - \alpha_i^* \} \quad (3)$$

$$\delta\alpha_i = \min \{ \max[\gamma(-E_i - \varepsilon), -\alpha_i], C - \alpha_i \} \quad (4)$$

- c. Setelah ditemukan nilai lagrange, tahap berikutnya adalah lakukan pada setiap data latih persamaan 5 dan 6

$$\alpha_i = \alpha_i + \delta\alpha_i \quad (5)$$

$$\alpha_i^* = \alpha_i^* + \delta\alpha_i^* \quad (6)$$

4. Lakukan secara berulang langkah ketiga hingga mencapai iterasi maksimum atau $\max(|\delta\alpha_i|) < \varepsilon$ dan $\max(|\delta\alpha_i^*|) < \varepsilon$
5. Dapat dianggap suatu *Support Vector* jika syarat $(\alpha_i^* - \alpha_i) \neq 0$ telah dipenuhi, yang berarti terjadi perbedaan nilai antara kedua variabel.
6. Menghitung dengan fungsi regresi :

$$f(x) = \sum_{i=1}^l (\alpha_i^* - \alpha_i)(K(x_i, x) + \lambda^2) \quad (7)$$

Keterangan:

| | |
|------------------------------------|--|
| R_{ij} | = matriks Hessian pada baris ke- i dan kolom ke- j |
| $K(x_i, x)$ | = fungsi kernel yang digunakan |
| λ^2 | = variabel skalar |
| l | = banyak data yang digunakan |
| E_i | = nilai error ke- i |
| y_i | = nilai aktual data latih ke- i |
| α_j^*, α_j | = nilai <i>Lagrange Multiplier</i> |
| l | = banyak data yang digunakan |
| $\delta\alpha_i^*, \delta\alpha_i$ | = perubahan nilai α_i dan α_i^* |
| ε | = nilai epsilon |
| γ | = nilai <i>learning rate</i> |
| C | = variabel slack |

2.3 Flower Pollination Algorithm (FPA)

Dalam implementasi algoritma *flower pollination* disesuaikan dengan penyerbukan bunga yang sebenarnya yaitu dengan konsep penyerbukan yang terdiri atas dua jenis: penyerbukan sendiri (penyerbukan lokal) dan penyerbukan silang (penyerbukan global). Penyerbukan lokal terjadi ketika penyerbukan dengan serbuk sari yang berasal dari bunga yang sama atau bunga berbeda pada satu tanaman. Penyerbukan global terjadi apabila gamet serbuk sari yang dibawa oleh penyerbuk seperti serangga dapat mencapai jarak yang jauh dan bergerak dengan kisaran waktu yang lama (Chiroma, dkk., 2016). Direpresentasikan ke dalam persamaan 8 yang digunakan ketika kondisi penyerbukan global yaitu ketika nilai

probabilitas lebih besar dari nilai *random* dan persamaan 15 digunakan ketika kondisi penyerbukan lokal yaitu ketika nilai *probabilitas* lebih kecil dari nilai *random*, sebagai berikut:

$$x_i^{t+1} = x_i^t + L(B - x_i^t) \quad (8)$$

Berikut fungsi untuk jarak penyerbukan bunga:

$$L \sim \frac{\lambda\Gamma(\lambda) \sin(\frac{\pi\gamma}{2})}{\pi} \frac{1}{S^{1+\lambda}}, (S \gg S_0 > 0) \quad (9)$$

$$S = \frac{u}{|v|^{1/\beta}} \quad (10)$$

$$\sigma_u = \left\{ \frac{\Gamma(1+\beta) \sin(\frac{\pi\beta}{2})}{\Gamma[\frac{(1+\beta)}{2}] \beta 2^{\frac{\beta-1}{2}}} \right\}^{1/\beta} \quad (11)$$

$$N(0,1) = \frac{x-\mu}{\sigma} \quad (12)$$

$$\sigma = \sqrt{\frac{\frac{1}{N} - (\sum_{i=1}^N (x_i - \bar{x})^2)}{N-1}} \quad (13)$$

$$\Gamma(n) = \int_0^\infty t^{n-1} e^{-t} \quad (14)$$

$$x_i^{t+1} = x_i^t + \varepsilon(x_j^t - x_k^t) \quad (15)$$

Keterangan:

| | |
|-------------------|---|
| x_i^t | = solusi vektor i pada iterasi t |
| B | = solusi terbaik saat ini |
| L | = jarak penyerbukan oleh serangga |
| $\Gamma(\lambda)$ | = fungsi gamma standar |
| λ | = parameter ukuran penyerbukan |
| γ | = ukuran <i>learning rate</i> untuk operasi optimasi dengan FPA |
| S | = <i>symmetric Levy stable distribution</i> |
| u | = distribusi normal $N(0,1) * \sigma_u$ |
| v | = distribusi normal $N(0,1)$ |
| β | = beta dengan nilai 0 sampai dengan 2 |
| σ_u | = sigma u |
| N | = banyaknya nilai yang akan dicari standard deviasinya |
| x_i | = data berdistribusi normal indeks ke i |
| \bar{x} | = rata-rata nilai berdistribusi normal |
| n | = nilai yang akan dihitung fungsi gamma nya |
| x | = variabel peubah |
| e | = 2.71828 |
| x_i^t | = solusi vektor i pada iterasi t |
| ε | = distribusi seragam $[0,1]$ |
| x_k^t | = solusi vektor k pada iterasi t |

2.4 Support Vector Regression (SVR) dan Flower Pollination Algorithm (FPA)

Tahapan metode *hybrid* SVR-FPA untuk prediksi penerimaan zakat adalah sebagai berikut:

1. Inisialisasi parameter dan data.
2. Penentuan batas nilai untuk parameter yang dioptimasi dan inisialisasi sebanyak N *flower* sebagai populasi.
3. Menghitung nilai *fitness* dengan pelatihan SVR dan mencari x_{best} .
4. Ulangi tahap berikut hingga iterasi maksimal:
 - a. Bangkitkan nilai *random* untuk tiap dimensi individu seluruh populasi.
 - b. Jika $random < p$ lakukan penyerbukan global, dan jika $random \geq p$ lakukan penyerbukan lokal.
 - c. Evaluasi hasil reposisi penyerbukan dengan sebelum penyerbukan dan dapatkan solusi terbaik untuk tiap individu atau *flower* seluruh populasi, dan *update* x_{best} .
5. x_{best} yang didapatkan dari iterasi maksimal FPA sebagai solusi terbaik untuk parameter SVR yang dioptimasi.
6. Lakukan perhitungan SVR untuk fungsi regresi dan nilai *fitness* dengan koefisien parameter dari FPA.

2.5 Normalisasi Data

Normalisasi data merupakan metode *preprocessing* yang bertujuan untuk menyamakan data agar berada pada jarak tertentu (S.Gopal, dkk., 2015). Pada penelitian ini menggunakan metode *Min-Max Normalization*. Rumus normalisasi ditunjukkan pada persamaan 16.

$$x' = \frac{(x - x_{min})}{x_{max} - x_{min}} \tag{16}$$

Keterangan:

- x' = hasil normalisasi
- x = data yang akan di normalisasi
- x_{max} = nilai maksimum dari keseluruhan data yang digunakan
- x_{min} = nilai minimum dari keseluruhan data yang digunakan

Sedangkan denormalisasi digunakan untuk mengembalikan data pada besar nilai yang sebenarnya, dapat diimplementasikan dengan persamaan 17.

$$x = (x' \times (x_{max} - x_{min})) + x_{min} \tag{17}$$

2.6 Nilai Evaluasi

Nilai evaluasi yang digunakan pada penelitian ini adalah *Mean Absolute Percentage Error* (MAPE) dengan tujuan mengetahui besarnya akurasi dari hasil peramalan yang didapatkan dari selisih antara nilai ramalan dan nilai aktual atau *error rate* (Mathaba, dkk., 2014). Nilai *fitness* didapat dari perhitungan $1/(1+MAPE)$, semakin besar hasil perhitungan nilai *fitness* menunjukkan solusi yang dihasilkan juga semakin baik. Perhitungan MAPE ditunjukkan dengan persamaan 18:

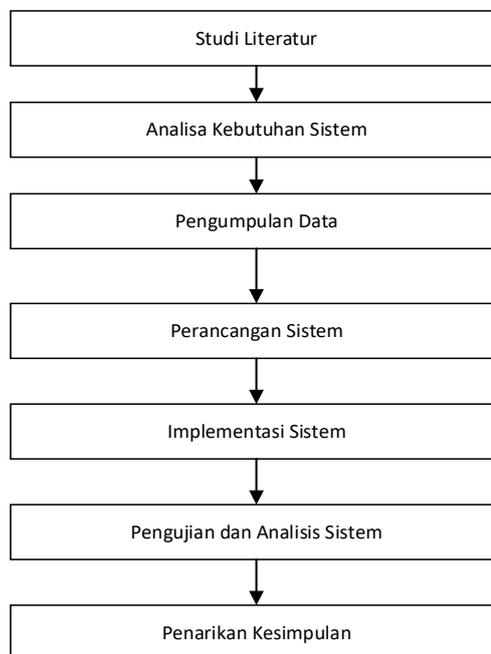
$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \times 100 \right| \tag{18}$$

Keterangan:

- \hat{y}_i = nilai hasil ramalan
- y_i = nilai actual
- n = banyaknya data yang digunakan

3. METODOLOGI

Tahapan yang dilakukan pada penelitian ini ditunjukkan pada Gambar 1 berupa Diagram Alir Metodologi Penelitian.



Gambar 1. Diagram Alir Metodologi Penelitian

3.1. Data Penelitian

Data yang digunakan pada penelitian ini adalah dengan menggunakan data historis penerimaan zakat dari lembaga pengelola zakat wilayah Malang “Lembaga Amil Zakat Infaq dan Shadaqah (LAZISMU) Malang” pada tiap

periode pengumpulan yaitu tiap bulan dari bulan Juli 2011 hingga Oktober 2016.

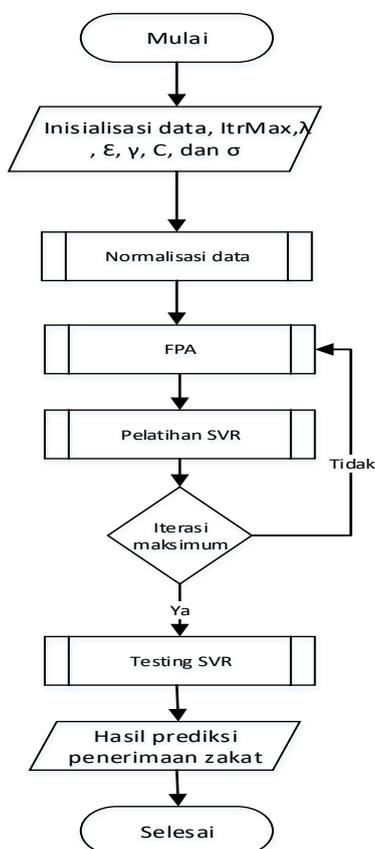
4. PERANCANGAN

Pada bagian perancangan diberikan penjelasan tentang penyelesaian permasalahan prediksi penerimaan zakat menggunakan *Support Vector Regression* (SVR) dengan *Flower Pollination Algrithm* (FPA). Diagram alir untuk perancangan sistem prediksi dengan SVR-FPA ditunjukkan pada Gambar 2.

Tahapan awal dari implementasi SVR-FPA untuk prediksi penerimaan zakat dimulai dengan inisialisasi populasi awal dan perhitungan nilai *fitness* yang ditunjukkan pada Tabel 1.

Tabel 1. Inisialisasi Populasi dan Nilai Fitness

| Inisialisasi flower | λ | ϵ | CLR | C | fitness Xi |
|---------------------|-----------|------------|-------|----|------------|
| Flower 1 | 0.1 | 0.0000 | 0.005 | 10 | 0.01579576 |
| Flower 2 | 0.3 | 0.0002 | 0.002 | 30 | 0.01322576 |
| Flower 3 | 0.4 | 0.001 | 0.072 | 65 | 0.01217060 |
| Flower 4 | 0.6 | 0.0072 | 0.05 | 15 | 0.01224970 |
| Flower 5 | 0.7 | 0.05 | 0.006 | 17 | 0.01613195 |



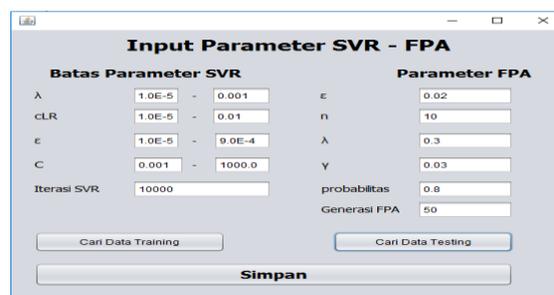
Gambar 2. Diagram Alir SVF-FPA

5. IMPLEMENTASI

Implementasi antarmuka yang digunakan pada sistem prediksi penerimaan zakat menggunakan *Support Vector Regression* (SVR) dengan *Flower Pollination Algorithm* (FPA) terdiri atas halaman utama dan halaman input, seperti pada Gambar 3 dan 4.



Gambar 3. Halaman Utama Sistem



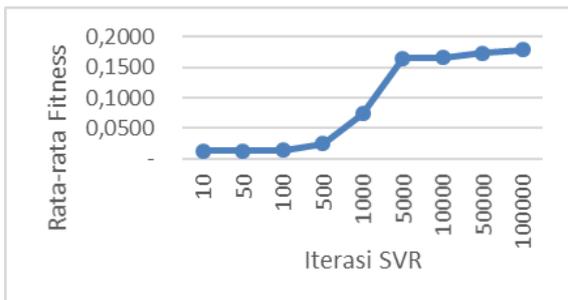
Gambar 4. Halaman Input Data Sistem

6. PENGUJIAN

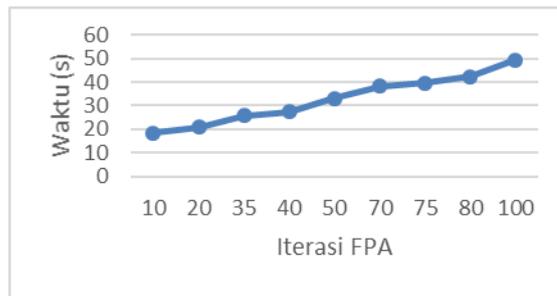
Pengujian yang dilakukan terhadap sistem terdiri atas 3 macam, yaitu pengujian jumlah iterasi SVR dan FPA, pengujian batas minimal dan maksimal parameter SVR, serta pengujian variasi data latih dan data uji. Tujuannya adalah menemukan kombinasi iterasi, parameter, dan data yang mampu memberikan hasil prediksi yang optimal. Pengujian dilakukan berulang sebanyak 10 kali terhadap masing-masing nilai yang diujikan.

6.1 Pengujian Jumlah Iterasi SVR dan FPA

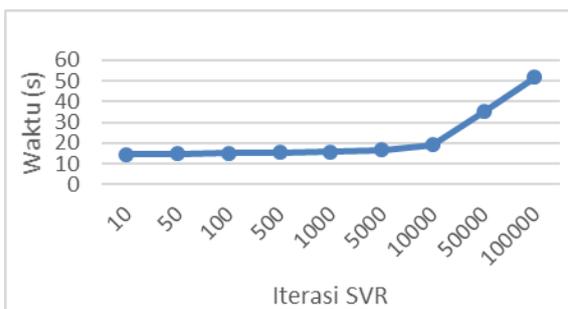
Pengujian pertama yang dilakukan adalah jumlah iterasi SVR dan FPA dengan tujuan menemukan banyak iterasi SVR dan FPA yang mampu memberikan hasil prediksi yang optimal. Hasil pengujian jumlah iterasi SVR ditunjukkan pada Gambar 5 dan Gambar 6, sedangkan hasil pengujian jumlah iterasi FPA ditunjukkan pada Gambar 7 dan Gambar 8.



Gambar 5. Grafik Rata-rata Fitness Pengujian Iterasi SVR

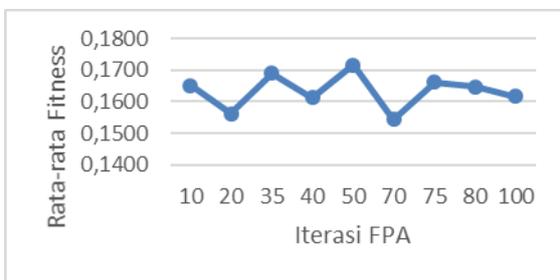


Gambar 8. Grafik Waktu Komputasi Pengujian Iterasi FPA



Gambar 6. Grafik Waktu Komputasi Pengujian Iterasi SVR

Berdasarkan hasil pengujian banyak iterasi SVR, jumlah iterasi SVR yang memberikan hasil prediksi terbaik adalah 100000 dengan nilai rata-rata *fitness* 0.1788. Dari hasil pengujian yang telah dilakukan semakin meningkat jumlah iterasi SVR yang digunakan, maka rata-rata *fitness* yang dihasilkan juga mengalami peningkatan ditunjukkan pada Gambar 5. Hal ini dikarenakan jumlah iterasi SVR mempengaruhi tingkat presisi dari hasil nilai SVR. Sementara itu, semakin meningkat jumlah iterasi SVR yang digunakan juga akan menyebabkan terjadinya peningkatan waktu komputasi yang digunakan. Hasil pengujian jumlah iterasi SVR terhadap waktu komputasi ditunjukkan pada Gambar 6.



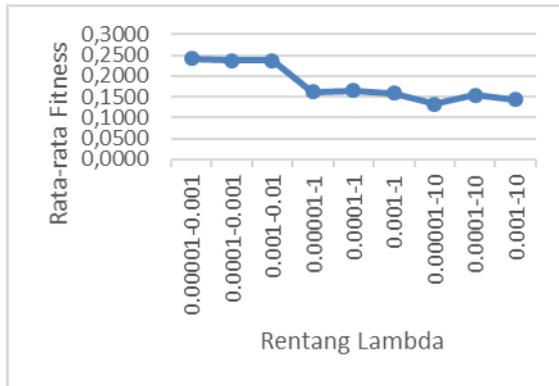
Gambar 7. Grafik Rata-rata Fitness Pengujian Iterasi FPA

Berdasarkan hasil pengujian banyak iterasi FPA, jumlah iterasi terbaik FPA yang memberikan hasil prediksi terbaik adalah 50 dengan nilai rata-rata *fitness* yaitu 0.1715. Dari analisa hasil pengujian iterasi FPA terhadap rata-rata *fitness* yang ditunjukkan pada Gambar 7 didapatkan hasil yaitu semakin besar iterasi FPA bukan berarti semakin tinggi hasil *fitness* yang dihasilkan karena sifat dari FPA yaitu *stochastic* atau *random*, namun menyebabkan waktu komputasinya meningkat ditunjukkan pada Gambar 8.

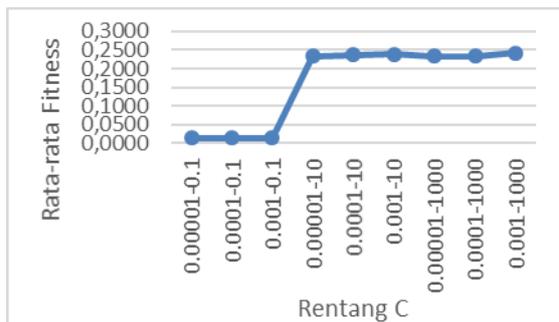
6.2 Pengujian Batas Minimum dan Maksimum Parameter SVR

Pengujian batas minimum dan maksimum parameter SVR bertujuan menemukan kombinasi batas yang dijadikan rentang nilai untuk parameter SVR yang mampu memberikan hasil prediksi terbaik. Hasil pengujian batas minimum dan maksimum parameter *Lambda* ditunjukkan pada Gambar 9, parameter *C* pada Gambar 10, parameter *CLR* pada Gambar 11, dan untuk parameter *Epsilon* pada Gambar 12

Berdasarkan hasil pengujian rentang parameter *Lambda* yang ditunjukkan pada Gambar 9, rentang *Lambda* yang terbaik adalah 0.00001-0.001 dengan nilai *fitness* yaitu 0.2421. *Lambda* berkaitan dengan *augmented factor*, semakin besar nilai *Lambda* yang digunakan maka akan memberikan hasil yang optimal. Namun, apabila nilai *Lambda* yang digunakan terlalu besar menyebabkan melambatnya waktu komputasi dikarenakan kecepatan konvergensi yang lambat dan tidak stabilnya proses *learning* (Vijayakumar & Wu., 1999).

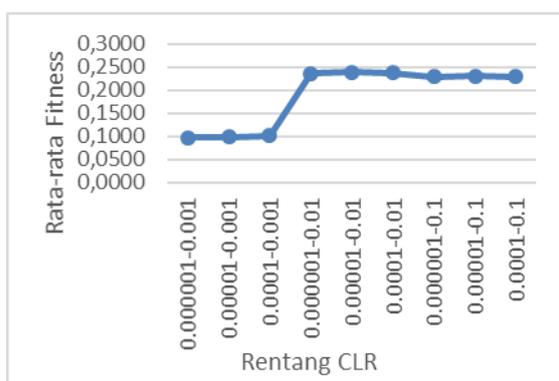


Gambar 9. Pengujian Rentang Parameter Lambda



Gambar 10. Pengujian Rentang Parameter C

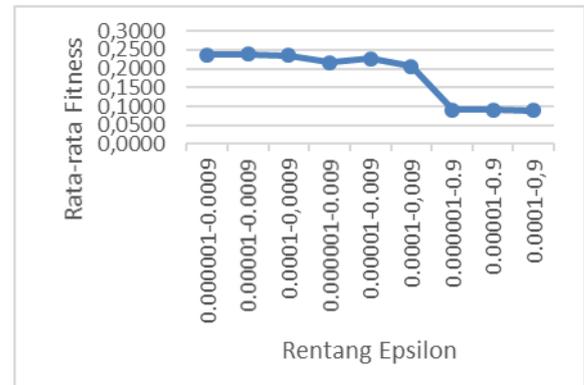
Berdasarkan pengujian batas minimal dan maksimal parameter C yang ditunjukkan pada Gambar 10, rentang parameter C yang terbaik adalah 0.001-1000 dengan nilai *fitness* yang dihasilkan yaitu 0.2421. Nilai *complexity* (C) merupakan variabel yang menampung nilai *penalty* akibat adanya pelanggaran toleransi yang berupa batas atas deviasi. Semakin besar nilai C, maka semakin jauh dengan standar deviasi (Maharesi., 2013).



Gambar 11. Pengujian Rentang Parameter CLR

Berdasarkan hasil pengujian batas minimal dan maksimal parameter CLR yang ditunjukkan pada Gambar 11, rentang parameter CLR yang terbaik adalah 0.0001-0.01 dengan nilai *fitness* yang dihasilkan adalah 0.2391. Konstanta *Learning Rate* (CLR) sebanding dengan nilai

learning rate, semakin besar nilai CLR, maka semakin cepat proses *learning* yang dilakukan.

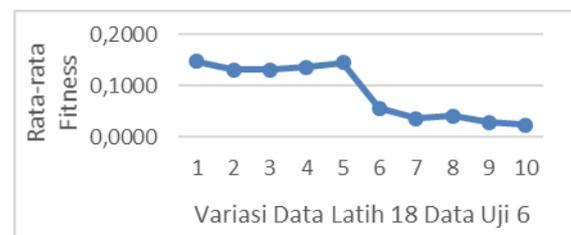


Gambar 12. Pengujian Rentang Parameter Epsilon

Berdasarkan hasil pengujian batas minimal dan maksimal parameter *Epsilon* yang ditunjukkan pada Gambar 12, rentang parameter *Epsilon* yang terbaik adalah 0.00001-0.0009 dengan nilai *fitness* yang dihasilkan adalah 0.2388. Nilai *Epsilon* menunjukkan tingkat ketelitian dari regresi, semakin besar nilai *epsilon* maka semakin tinggi tingkat ketelitian regresi sehingga mampu memberikan hasil yang lebih baik.

6.3 Pengujian Variasi Data Latih dan Data Uji

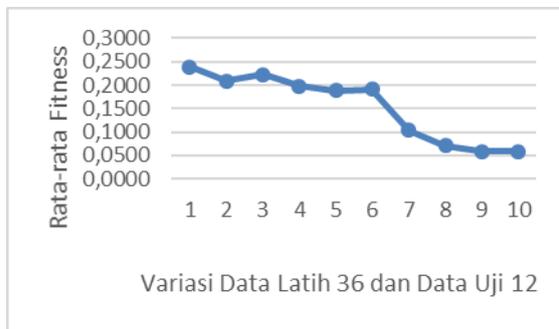
Pengujian berikutnya adalah pengujian variasi data latih dan data uji untuk menemukan kombinasi data yang memberikan hasil terbaik. Uji coba variasi data latih dan data uji dilakukan pada 3 bagian yang berbeda yaitu uji coba variasi data latih 18 bulan untuk melakukan prediksi 6 bulan ditunjukkan pada Gambar 13, uji coba variasi data latih 36 bulan untuk melakukan prediksi 12 bulan pada Gambar 14, dan uji coba variasi jumlah data latih untuk melakukan prediksi 6 bulan pada Gambar 15.



Gambar 13. Hasil Uji Coba Variasi Data Latih 18 Data Uji 6

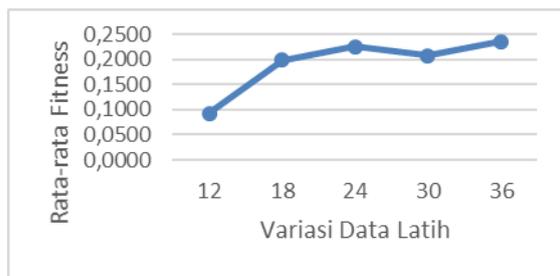
Berdasarkan hasil pengujian variasi data latih dan data uji pada Gambar 13, variasi data latih dan data uji yang memberikan hasil optimal adalah data bulan Februari 2014 - Juli 2015 yang

digunakan untuk melakukan prediksi penerimaan zakat pada bulan Agustus 2015 – Januari 2016. Hal ini dikarenakan data pada bulan tersebut cenderung stabil dibanding yang lainnya.



Gambar 14. Hasil Uji Coba Variasi Data Latih 36 Bulan dan Data Uji 12 Bulan

Berdasarkan grafik hasil uji coba variasi data latih dan data uji pada Gambar 14, dapat dilihat bahwa kombinasi data yang menghasilkan nilai rata-rata *fitness* terbaik adalah dengan data latih bulan Januari 2012 – Desember 2014 untuk melakukan prediksi penerimaan zakat pada bulan Januari 2015 – Desember 2015, ini dikarenakan pelatihan data untuk beberapa pengujian yang sebelumnya dilakukan adalah dengan menggunakan kombinasi data tersebut, sehingga pola data sudah dikenali dengan baik beserta nilai untuk masing-masing parameter yang digunakan pada pengujian saat ini.



Gambar 15. Hasil Uji Coba Variasi Jumlah Data Latih

Sedangkan berdasarkan grafik hasil uji coba variasi data latih dan data uji pada Gambar 15 penggunaan data latih sebanyak 36 bulan memberikan hasil yang paling baik, dengan bulan Januari 2012 – Desember 2014 sebagai data latih dan Januari 2015 – Desember 2015 sebagai data uji. Dari Gambar 15 dapat ditarik kesimpulan bahwa semakin banyak jumlah data latih yang digunakan, tidak menjamin bahwa nilai *fitness* yang dihasilkan juga akan mengalami peningkatan.

6.4 Analisis Global Hasil Pengujian

Berdasarkan analisis dari keseluruhan pengujian yang telah dilakukan terhadap sistem, dapat disimpulkan bahwa jumlah iterasi yang memberikan hasil terbaik pada pengujian kali ini untuk SVR adalah sejumlah 10000 dan untuk FPA adalah 50 dengan nilai *fitness* yang dihasilkan adalah 0.2497 atau MAPE 3.0048.

Batas minimum dan maksimum untuk parameter *lambda* yang memberikan hasil *fitness* terbaik pada rentang 0.00001-0.001, untuk batas minimum dan maksimum dari parameter *C* memberikan hasil terbaik pada rentang 0.001-1000, untuk parameter *CLR* memberikan hasil terbaik pada rentang 0.00001-0.01, untuk parameter *Epsilon* memberikan hasil terbaik pada rentang 0.00001-0.0009. Sedangkan dari hasil pengujian variasi data latih yang dilakukan pada pengujian kali ini terhadap 18 bulan data latih dan 6 bulan data uji dihasilkan yang terbaik adalah kombinasi bulan Februari 2014 – Juli 2015 sebagai data latih dan bulan Agustus 2015 – Januari 2016 sebagai data uji, untuk pengujian terhadap 36 bulan data latih dan 12 bulan data uji kombinasi terbaik dihasilkan pada bulan Januari 2012 – Desember 2014 sebagai data latih dan Januari 2015 – Desember 2015 sebagai data uji. Jumlah data latih yang memberikan hasil terbaik adalah 36 bulan.

Sesuai dengan analisis hasil dan pengujian yang telah dilakukan, untuk pengujian jumlah iterasi SVR dan FPA diberikan waktu komputasi. Hal ini dikarenakan jumlah iterasi SVR dan FPA yang digunakan pada saat pengujian sangat berpengaruh terhadap kecepatan komputasi untuk memberikan hasil prediksi zakat. Waktu komputasi yang digunakan untuk melakukan prediksi penerimaan zakat dengan 50 iterasi FPA sudah cukup lama yaitu 33 s. Mengingat waktu komputasi yang diperlukan sudah cukup lama, maka pada pengujian tersebut hanya menggunakan iterasi SVR sebesar 10000 dengan tujuan untuk menghemat waktu komputasi yang digunakan. Detail hasil prediksi penerimaan zakat dengan 50 iterasi FPA dapat dilihat pada Gambar 16.

Grafik pada Gambar 17 menunjukkan hasil prediksi penerimaan zakat dengan menggunakan iterasi SVR sebanyak 100000. Berdasarkan Gambar 17 hasil prediksi penerimaan zakat dengan 100000 iterasi SVR menghasilkan *fitness* yang lebih baik dari hasil prediksi pada Gambar 16 yaitu sebesar 0.1788

sedangkan untuk nilai *fitness* dengan 50 iterasi FPA hanya 0.1715. Hal ini dikarenakan pada pengujian 50 iterasi FPA hanya menggunakan iterasi SVR sebesar 10000, sehingga hasilnya kurang optimal. Dari hasil analisis tersebut sebaiknya iterasi SVR yang digunakan adalah 100000 untuk mendapatkan hasil yang lebih optimal, namun dengan konsekuensi yaitu waktu komputasi yang lama untuk mendapatkan hasil prediksi penerimaan zakat. Detail hasil penerimaan zakat dengan menggunakan 100000 iterasi SVR dapat dilihat pada Gambar 17.



Gambar 16. Hasil Prediksi Pengujian Iterasi 50 FPA



Gambar 17. Hasil Prediksi Pengujian 100000 SVR

7. KESIMPULAN DAN SARAN

Flower Pollination Algorithm (FPA) dapat diimplementasikan pada kasus prediksi penerimaan zakat menggunakan *Support Vector Regression* (SVR) untuk menemukan koefisien terbaik dari parameter SVR yang dioptimasi.

Pada penelitian ini terdapat empat parameter dari SVR yang dioptimasi dengan FPA yaitu nilai *lambda* (λ), nilai kompleksitas (C), nilai konstanta *learning rate* (CLR), dan nilai *epsilon* (ϵ). Dengan batas rentang untuk masing-masing parameter berbeda yaitu [0.00001 , 0.001] untuk *lambda*, [0.001 , 1000] untuk C , [0.0001 , 0.01] untuk CLR , dan [0.00001 , 0.0009] untuk *epsilon*. Sedangkan *error* yang dihasilkan pada penelitian ini sudah cukup kecil dan baik untuk menghasilkan prediksi penerimaan zakat, ditunjukkan dengan nilai 0.2497 dalam *fitness* atau 3.0048 dalam MAPE yang berarti rata-rata selisih antara data aktual dengan hasil prediksi adalah Rp144.741, dengan menggunakan iterasi SVR 10000, dan iterasi FPA 50.

Penelitian selanjutnya yang bisa dilakukan adalah implementasi SVR dan FPA dengan menambahkan jumlah iterasi SVR dengan menggunakan pemrosesan paralel yang digunakan untuk melakukan uji coba parameter dan data agar mampu menghasilkan prediksi dengan nilai *error* yang cukup kecil dan waktu komputasi yang diperlukan juga semakin cepat. Selain itu pada penelitian berikutnya bisa melakukan optimasi parameter SVR yang belum dioptimasi pada penelitian saat ini. Adapun parameter yang belum dilakukan optimasi nilainya pada penelitian ini adalah nilai *sigma* (σ). Dengan tujuan mendapatkan nilai yang optimal untuk setiap parameter SVR, sehingga dapat memberikan hasil prediksi yang lebih baik.

DAFTAR PUSTAKA

- Abdelaziz, A., Ali, E. & Elazim, S. A., 2016. *Optimal Sizing and Locations of Capacitors in Radials Distribution System Via Flower Pollination Optimization Algorithm and Power Loss Index*. Engineering Science and Technology an International Journal, Volume 19, pp. 610-618.
- Abdel-Baset, M. & Hezam, I. M., 2015. *An Improved Flower Pollination Algorithm for Ratios Optimization Problems*. Applied Mathematics & Information Sciences Letters an International Journal, Volume 3, pp. 83-91.
- Abdel-Raouf, O., Abdel-Baset, M. & El-henawy, 2014. *A New Hybrid Flower Pollination Algorithm for Solving Constrained Global Optimization Problems*. International Journal of

- Applied Operational Research, 4(22), pp. 1-13.
- Agresti, A., 1990. *Categorical Data Analysis*. 2nd penyunt. Geinesville, Florida: Wiley Interscience.
- Alfredo, Jondri & RIsmala, R., t.thn. *Prediksi Harga Saham menggunakan Support Vector Regression dan Firefly Algorithm*. Departemen Informatika, Universitas Telkom.
- Anandhi, V. & Chezian, D. R. M., 2013. *Support Vector Regression in Forecasting*. International Journal of Advanced Research in Computer and Communication Engineering, 2(10), pp. 4148-4151.
- Anon., 2013. *Distribusi Normal*. [Online] Available at: <http://www.rumusstatistika.com/2013/07/rumus-distribusi-normal-distribusi-gauss.html> [Diakses 29 November 2016].
- Bi, L., Tsimhoni, O. & Liu, Y., 2011. *Using the Support Vector Regression Approach to Model Human Performance*. IEEE Transactions on System, Man, and Cybernetics- Part A : System and Human, 41(3), pp. 410-417.
- Chiroma, H. et al., 2016. *A New Approach for Forecasting OPEC Potrelium Consumption based on Neural Network Train by using FLower Pollination Algorithm*. Applied Soft Computing, Volume 48, pp. 50-58.
- Claveria, O., Monte, E. & Torra, S., 2015. *Regional Forecasting with Support Vector Regression: The Case of Spain*. Research Institute of Applied Economics, Volume 7.
- Hoang, N.-D., Bui, D. T. & Kuo-Wei, L., 2016. *Groutability Estimation of Grouting Processes with Cements Grouts using Differential FLower Pollination Optimized Support Vector Regression*. Applied Soft Computing, Volume 45, pp. 173-186.
- Lukasik, S. & Kowalski, P. A., t.thn. *Study of Flower Pollination for Continuous Optimization*. System Research Institute, Polish Academy of Science.
- Madura, J., 2011. *International Finance Management*.
- Pardede, C., t.thn. *Kalkulus 4*. Dalam: S. T. MESIN, penyunt. Kalkulus. s.l.:Universitas Gunadarma.
- Patro, S. & Sahu, K., t.thn. *Normalization: A Preprocessing Stage*. India: Department of SCE&IT, VSSUT, Burla.
- Pebrianita, 2013. *Pengaruh Zakat yang dikelola Bazda terhadap Pengentasan Kemiskinan di Kota Padang*. Skripsi S1 Ilmu Ekonomi, Fakultas Ekonomi.
- Preasad, R., Veera, R. & T., G. M., 2016. *Application of Flower Pollination Algorithm for Optimal Placement and Sizing of Distrbuted Generation in Distribution System*. Journal of Electrical System and Information Technology, pp. 14-22.
- Rajkumar, N. & Jaganathan, P., 2013. *A New RBF Kernel Based Learning Method Applied to Multiclass Dermatology Diseases Classification*. Proceeding of 2013 IEEE COnference of Information and Communication Technologies (ICT 2013).
- Ren, Y. & Bai, G., 2010. *Determinaton of Optimal SVM Parameters by Using GA/PSO*. Journal of Computers, 5(8).
- RI, U.-u., 1998. *Pengelolaan Zakat*. [Online] Available at: [www/bpkp.go.id/u/filedownload/2/1/1997.bpkp](http://www.bpkp.go.id/u/filedownload/2/1/1997.bpkp) [Diakses 29 Agustus 2016].
- Sedgewick, R. & Wayne, K., 2014. *Introduction Programming in Java An Interdiscipline Approach: Scientific Computation*. s.l.:Universitas Priceton.
- Shi, K. et al., 2015. *Support Vector Regression Based Indoor Location in IEEE 802.11 Environments*. Hindawi Publishing Corporation Mobila Information System, Volume 2015, pp. 1-14.
- Siradj, M., 2014. *Jalan Panjang Legislasi Syariat Zakat di Indonesia: Studi terhadap Undang-Undang Nomor 23 tahun 2011 tentang Pengelolaan Zakat*. Jurnal Bimnas Islam, 7(3), pp. 409-449.
- Vijayakumar, S. & Wu, S., 1999. *Sequential Support Vector Classifier and Regression*. International Conferences

on Soft Computing, pp. 610-619.

Wu, C.-H., Ho, J.-M. & Lee, D., 2004. *Travel-Time Prediction With Support Vector Regression*. IEEE Transactions on Intelligent Transportation System , 5(4), pp. 276-281.