

repository.ub.ac.id

PERAMALAN KONSUMSI BAHAN BAKAR MINYAK (BBM) DI INDONESIA DENGAN METODE *HYBRID* ALGORITMA GENETIKA DAN *SUPPORT VECTOR REGRESSION*

Rofiqoh Ainun Zakiyah¹⁾, Imam Cholissodin, S.Si.,M.Kom²⁾, Dian Eka Ratnawati,
S.Si.,M.Kom³⁾

Program Studi Informatika / Ilmu Komputer
Fakultas Ilmu Komputer

Universitas Brawijaya, Malang 65145, Indonesia

email : aries_nunz[at]yahoo.com¹⁾, imamcs[at]ub.ac.id²⁾, dian_ilkom[at]ub.ac.id³⁾

Abstrak

Saat ini kebutuhan yang sangat penting untuk dipenuhi agar berlangsungnya berbagai macam kegiatan sehari-hari adalah bahan bakar minyak. Jika terjadi keterbatasan dalam memenuhi kebutuhan bahan bakar minyak dapat mengakibatkan kegiatan produksi, distribusi dan konsumsi menjadi terlambat. Hal tersebut bisa mengakibatkan terjadinya *demand for oil* yang meningkat, harga minyak internasional menjadi berubah-ubah dan gas dalam negeri yang melambung tinggi. Dengan melakukan peramalan konsumsi bahan bakar minyak akan sangat berguna untuk kelangsungan kegiatan sehari-hari dari berbagai sektor dan menghindari adanya kesenjangan negative antara jumlah produksi dan konsumsi bahan bakar minyak. Banyak metode peramalan yang telah digunakan untuk meramalkan data yang bersifat non linier seperti *Support Vector Regression* (SVR) yang terbukti pada beberapa kasus peramalan dapat memberikan hasil peramalan yang baik, seperti pada peramalan konsumsi energi harian dan peramalan kebutuhan bahan bakar premium. Namun, untuk hasil yang lebih optimal dapat digunakan metode optimasi seperti *Hybrid* Algoritma Genetika. Penelitian mengenai penggunaan metode optimasi *Hybrid* Algoritma Genetika untuk peramalan menggunakan SVR pernah digunakan pada peramalan beban listrik dan terbukti metode tersebut dapat menghasilkan nilai *error* yang kecil. Sesuai dengan hasil pengujian yang dilakukan menggunakan data yang didapatkan dari *website* www.bp.com berupa jumlah konsumsi BBM di Indonesia dari tahun 1965-2014, metode SVR yang dioptimasi dengan HGA dapat menghasilkan MAPE yang berkisar antara 3.64 hingga 4.65.

Kata Kunci : Bahan bakar minyak, SVR, HGA, MAPE.

Abstract

Currently the most important thing to accomplish daily activities is fuel oil. If there are some trouble related fuel oil needs, it can affect production, distribution, and consumption. This kind of trouble can result in demand for oil increased, the international oil prices become volatile and domestic gas soared. By forecasting the consumption of fuel oil will be really useful for daily activities in various sectors and avoid the negative gap between the production and consumption of fuel oil. There are so many forecasting methods that have been used to predict non-linear data such as *Support Vector Regression* (SVR) which is proven a good result in some forecasting cases like daily energy consumption forecasting and premium fuel needs prediction. However, optimization methods can be used for more optimal result such as *Hybrid Genetic Algorithm*. *Hybrid Genetic Algorithm* optimization for forecasting using the SVR has been used in electric load forecasting research and produce a small error value. According to the result of testing performance using fuel oil consumption data 1965-2014 from www.bp.com, SVR methods with HGA optimization can produce MAPE between 3.64 to 4.65.

Keywords : Fuel Oil, SVR, HGA, MAPE

1. PENDAHULUAN

Bahan bakar minyak merupakan salah satu kebutuhan yang sangat penting untuk menjalankan berbagai macam aktivitas dalam kehidupan sehari-hari. Banyaknya masyarakat yang telah membeli kendaraan untuk menunjang aktivitas mereka mengakibatkan cadangan jumlah produksi bahan bakar minyak menjadi menipis. Pertamina telah mengimpor minyak pada harga internasional dan menjual pada konsumen dengan harga bersubsidi, jika terjadi keterbatasan dalam memenuhi kebutuhan bahan bakar minyak dapat mengakibatkan kegiatan produksi, distribusi dan konsumsi menjadi terlambat. Hal tersebut bisa mengakibatkan terjadinya *demand for oil* yang meningkat, harga minyak internasional menjadi berubah-ubah dan gas dalam negeri yang melambung tinggi^[1]. Menurut data dari *Statistical Review of World Energy* 2015, jumlah produksi minyak di Indonesia beberapa tahun terakhir mengalami penurunan dari tahun 2010 sebesar 1003.01758575342 barrels, 2011 sebesar 952.284732613698, hingga 2014 sebesar 852.267507441095. Sedangkan jumlah konsumsi minyak di Indonesia beberapa bulan terakhir mengalami peningkatan dari tahun 2008 hingga 2014.

Berdasarkan penjelasan mengenai jumlah produksi dan jumlah konsumsi minyak di Indonesia, bisa dikatakan bahwa Indonesia saat ini mengalami kesenjangan negatif yakni jumlah konsumsi minyak lebih tinggi daripada jumlah produksi minyak. Sumber energi terbarukan yang ada di Indonesia seperti biodiesel dari tanaman jarak pagar dapat dimanfaatkan untuk mengurangi jumlah konsumsi bahan bakar minyak di Indonesia. Namun, sumber energi tersebut mengakibatkan adanya penumpukan CO₂ yang akan meningkatkan temperatur udara bumi. Selain itu, dengan meningkatkan harga BBM mengakibatkan kendala ekonomi bagi masyarakat miskin. Oleh karena itu, seiring dengan berlakunya kebijakan mengenai bahan bakar baru dan kenaikan harga BBM, hendaknya dibuat sebuah pemodelan untuk peramalan jumlah konsumsi BBM di Indonesia. Hal ini bertujuan agar masyarakat dan pemerintah mampu menyeimbangkan jumlah produksi BBM, jumlah konsumsi BBM, produksi bahan bakar baru, maupun kenaikan harga BBM.

Penelitian yang terkait dengan metode Support Vector Regression dan Hybrid Algoritma Genetika telah dilakukan oleh Chih-Hung Wu (2009). Penelitian tersebut terfokus pada pendekatan metode yang digunakan yakni penggabungan antara metode HGA-SVR dalam melakukan peramalan. Hasil yang didapatkan dari penelitian tersebut adalah perbandingan nilai root mean square error (RMSE) metode GA-SVR dan HGA-SVR yakni 9.46 : 7.73. Nilai RMSE yang dihasilkan menunjukkan bahwa

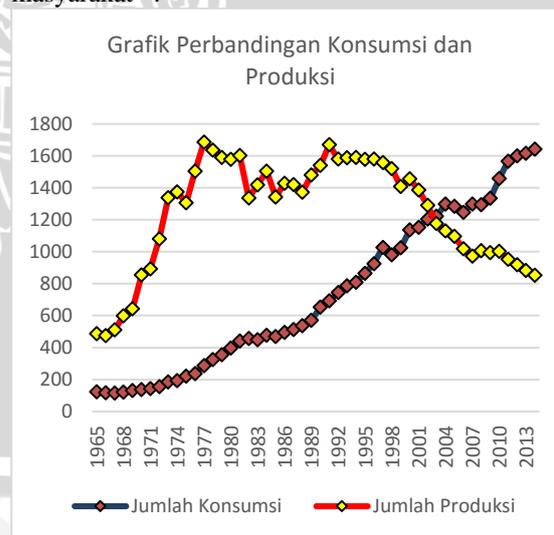
peramalan menggunakan HGA-SVR dapat menghasilkan nilai error rate peramalan yang rendah^{[2][5]}.

Berdasarkan pada penelitian yang menggunakan metode HGA-SVR yang mendapatkan hasil terbaik, maka sebuah sistem peramalan akan dirancang menggunakan HGA-SVR dengan objek konsumsi BBM. Penggunaan metode *Support Vector Regression* pada penelitian ini didasarkan pada kemampuannya dalam menangani data dimensi tinggi pada fase *training* dan memiliki keakuratan yang tinggi^{[3][4]}. Metode HGA digunakan karena metode tersebut dapat memberikan hasil yang optimum dan mengurangi waktu dalam pencarian solusi^[3].

2. DASAR TEORI

2.1 Bahan Bakar Minyak

Bahan Bakar Minyak (BBM) merupakan salah satu kebutuhan yang harus terpenuhi dalam kehidupan sehari-hari baik rumah tangga ataupun dunia kerja. Seiring dengan meningkatnya aktivitas pembangunan diberbagai sektor yang ditunjukkan dengan peningkatan mobilitas barang maupun orang mengakibatkan kebutuhan bahan bakar minyak terus meningkat^[6]. Indonesia resmi menjadi negara pengimpor minyak sejak tahun 2004. Hal ini dikarenakan menurunnya tingkat produksi minyak disatu sisi sementara disisi lainnya tingkat konsumsi minyak terus meningkat yang ditunjukkan pada Gambar 1. Salah satu produk bahan bakar minyak (BBM) yang paling krusial adalah premium. Premium merupakan satu dari tiga produk bahan bakar bersubsidi yang paling banyak diminati oleh masyarakat^[7].



Gambar 1 Grafik Perbandingan Konsumsi dan Produksi

2.2 Support Vector Regression

Support Vector Regression (SVR) adalah sebuah model nonlinier yang digunakan untuk menyelesaikan permasalahan regresi. Proses

pelatihan SVR mirip dengan memecahkan masalah pemrograman kuadrat linier terkendala yang menyediakan nilai optimal yang unik dan tidak ada masalah minimum lokal^[8]. Berikut merupakan langkah – langkah metode sekuensial SVR:

1. Inisialisasi $\alpha_i = 0, \alpha_i^* = 0$. Kemudian dilakukan perhitungan matriks *hessian* yang ditunjukkan pada Persamaan 1.

$$[R]_{ij} = K(x_i, x_j) + \lambda^2 \quad (1)$$

2. Untuk masing-masing data training $i, j = 1, \dots, l$, lakukan

2.1 Hitung nilai *error* menggunakan Persamaan 2.

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

2.2 Hitung $\delta\alpha_i$ dan $\delta\alpha_i^*$ menggunakan Persamaan 3 dan Persamaan 4.

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

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

2.3 Update nilai α_i dan α_i^* dengan Persamaan 5 dan 6.

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

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

3. Jika proses telah mencapai pada iterasi yang telah ditentukan, maka algoritma selesai. Jika tidak maka ulangi langkah kedua.

4. Lakukan pengujian fungsi regresi seperti yang telah dijelaskan pada Persamaan 7.

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

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*.
- $\delta\alpha_i^*$ = merupakan variabel *slack*.
- $\delta\alpha_i$ = merupakan variabel *slack*.
- α_i, α_i^* = merupakan suatu nilai *Lagrange Multiplier*
- C = merupakan nilai kompleksitas.
- ε = merupakan nilai deviasi
- λ = variabel set untuk data *training*
- x_i = merupakan data ke- i
- x_j = merupakan data ke- j

2.3 Metode Kernel

Metode kernel merupakan sebuah teknik yang bisa digunakan untuk membangun sebuah fitur-fitur untuk permasalahan nonlinier yakni memetakan *input space* dan *feature space*^[9]. Metode kernel yang sering digunakan adalah^[10]:

- *Radial Basis Function* (RBF) kernel.
Perhitungan kernel RBF akan dijabarkan pada Persamaan 8.

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (8)$$

Dimana σ merupakan varian gaussian kernel.

- *Polinomial* kernel.
Rumus perhitungan kernel polinomial akan ditunjukkan pada Persamaan 9.

$$k(x_i, x_j) = (t + x_i^T x_j)^d \quad (9)$$

Dimana d merupakan derajat polinomial, t merupakan parameter polinomial.

- *Linear* kernel.
Persamaan 10 merupakan rumus yang digunakan pada *Linear* kernel.

$$k(x_i, x_j) = x_i^T x_j \quad (10)$$

2.4 Hybrid Algoritma Genetika

Pada pemodelan *hybrid* algoritma genetika dan *support vector regression* yang diimplementasikan menggunakan metode seleksi *elitism*. Pada metode seleksi *elitism* dapat menghasilkan kromosom yang bisa digunakan untuk generasi selanjutnya ditempatkan di proses perkawinan pada proses *crossover* dan mutasi. Setelah kromosom pasangan dipilih, satu atau lebih posisi kromosom akan dipilih secara acak untuk diproses lagi. Kromosom yang baru akan dikombinasikan dengan kromosom yang sudah terbentuk sebelumnya untuk menjadi generasi yang baru. Metode *crossover* yang digunakan adalah *adewuya's crossover* yang disajikan pada Persamaan 11, 12, dan 13^[4].

$$\begin{aligned} X_1^{old} &= \{x_{11}, x_{12}, \dots, x_{1n}\}, \\ X_2^{old} &= \{x_{21}, x_{22}, \dots, x_{2n}\} \end{aligned} \quad (11)$$

Perubahan jarak dekat :

$$\begin{aligned} X_1^{new} &= X_1^{old} + \sigma(X_1^{old} - X_2^{old}) \\ X_2^{new} &= X_2^{old} - \sigma(X_1^{old} - X_2^{old}) \end{aligned} \quad (12)$$

Perubahan jarak jauh :

$$\begin{aligned} X_1^{new} &= X_1^{old} + \sigma(X_2^{old} - X_1^{old}) \\ X_2^{new} &= X_2^{old} - \sigma(X_2^{old} - X_1^{old}) \end{aligned} \quad (13)$$

X_1^{old} dan X_2^{old} merupakan representasi dari

nilai kromosom sebelum proses *crossover*. X_1^{new} dan X_2^{new} merupakan representasi nilai kromosom baru yang telah mengalami proses *crossover*. Sedangkan σ merepresentasikan bilangan acak dengan batas (0,1).

Proses mutasi lanjutan dari *crossover* akan menunjukkan apakah kromosom tersebut harus



dimutasi atau tidak untuk generasi yang selanjutnya. Mutasi dalam model ini disajikan pada Persamaan 14, 15, dan 16^[11]:

$$X^{old} = \{x_1, x_2, \dots, x_n\} \dots\dots\dots (14)$$

$$X_k^{new} = LB_k + r \times (UB_k - LB_k) \dots\dots (15)$$

$$X^{new} = \{x_1, x_2, x_k^{new}, \dots, x_n\} \dots\dots\dots (16)$$

Dimana n merupakan banyak parameter, r merepresentasikan bilangan acak dengan batas (0,1), dan k merupakan lokasi mutasi. *Lower Bound* (LB) dan *Upper Bound* (UB) merupakan parameter batas bawah dan batas atas. Sedangkan untuk LB_k dan UB_k merupakan parameter batas bawah dan batas atas pada lokasi k .

2.5 Normalisasi Data dan Denormalisasi Data

Proses *preprocessing* data yang dilakukan pada Peramalan konsumsi BBM berupa normalisasi data. Hal ini bertujuan untuk standarisasi semua data yang digunakan dalam perhitungan sehingga data berada pada jarak tertentu^[12]. Proses normalisasi yang digunakan pada penelitian ini adalah *Min-Max normalization*. Perhitungan *Min-Max normalization* ditunjukkan pada Persamaan 17:

$$x' = \frac{(x - x_{min})}{x_{max} - x_{min}} \dots\dots\dots (17)$$

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

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 18 yang merupakan *reverse* dari Persamaan 17.

$$x = (x' \times (x_{max} - x_{min})) + x_{min} \dots\dots\dots (18)$$

2.6 Nilai Evaluasi

Nilai evaluasi yang digunakan adalah *Mean Absolute Percentage Error* (MAPE) karena MAPE tetap mempertahankan konvergen selama evolusi generasi^[11]. Untuk rentang nilai MAPE adalah $0 \leq MAPE \leq +\infty$ ^[13]. Penjabaran rumus MAPE akan dijelaskan pada Persamaan 19.

$$MAPE = \frac{1}{m} * \frac{\sum_{i=1}^m |\hat{y}_i - y_i|}{\hat{y}_i} * 100\% \dots\dots(19)$$

Sedangkan penjabaran rumus dari nilai fitness ditunjukkan pada Persamaan 20.

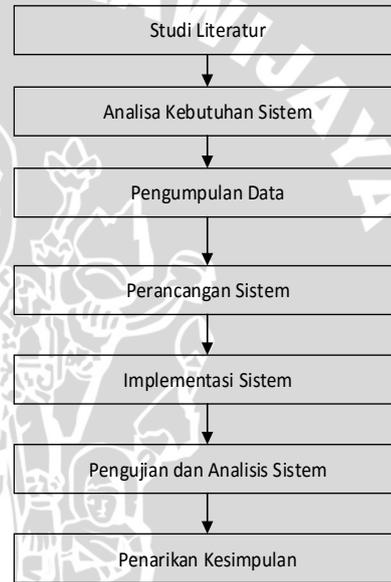
$$fitness = \frac{1}{1 + MAPE} \dots\dots\dots(20)$$

Keterangan:

- \hat{y}_i = Nilai aktual
- y_i = Nilai ramal

3. METODOLOGI PENELITIAN

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



Gambar 2 Diagram Alir Tahapan Penelitian

3.1 Data Penelitian

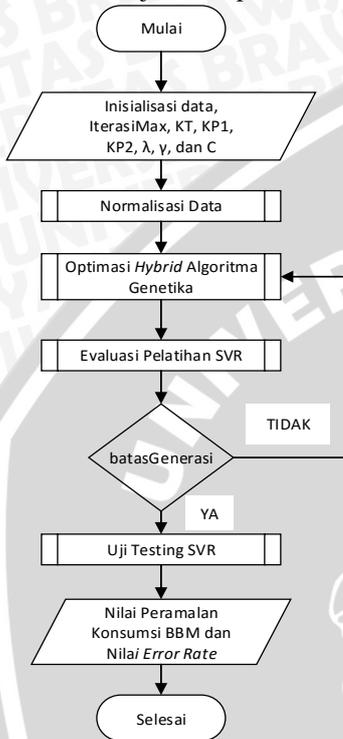
Data yang digunakan dalam penelitian ini merupakan data sekunder yang didapatkan melalui *website* www.bp.com. Data tersebut berupa jumlah konsumsi BBM di seluruh dunia pada tahun 1965-2014, namun pada penelitian ini yang digunakan adalah jumlah konsumsi BBM yang ada di Indonesia saja.

4. PERANCANGAN SISTEM

Peramalan konsumsi BBM dilakukan dengan membentuk model regresi, yang kemudian diuji untuk mendapatkan nilai *error rate*. Langkah awal yang dilakukan adalah inialisasi parameter metode SVR yang digunakan sebagai metode regresi pada penelitian ini, setelah itu melakukan normalisasi data yang digunakan, setelah proses normalisasi untuk fase *training*, metode regresi ada di dalam



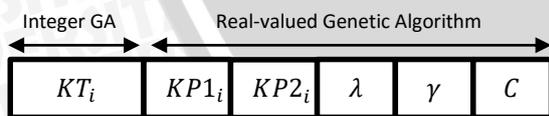
metode HGA, dimana HGA berfungsi sebagai metode optimasi yang menghasilkan parameter – parameter yang digunakan pada SVR. Setelah mencapai maksimum iterasi pada HGA, didapatkanlah *best parent* untuk data *training* yang diramalkan. Partikel yang berisi parameter terbaik tersebut akan digunakan untuk meramalkan data *testing* terpilih sehingga didapatkan hasil peramalan dan nilai *error* untuk fase *testing*. Diagram alir proses umum akan dijelaskan pada Gambar 3.



Gambar 3 Diagram Alir Proses Peramalan Konsumsi BBM

Langkah 1:

Inisialisasi data yang akan diolah, parameter SVR, dan parameter *Hybrid* Algoritma Genetika. Gambar 4 merupakan representasi kromosom yang digunakan.



Gambar 4 Representasi Kromosom

Langkah 2:

Normalisasi data menggunakan *min-max normalization*.

Langkah 3:

Inisialisasi *parent* pada *Hybrid* Algoritma Genetika. Pada Tabel 1 merupakan contoh inisialisasi *parent* yang digunakan.

Tabel 1 Inisialisasi *parent*

KT_i	$KP1_i$	$KP2_i$	λ	γ	C
2	0.7282	0.0289	0.1953	0.806	0.1512

Langkah 4:

Proses reproduksi diantaranya *crossover* dan mutasi.

Langkah 5:

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

Langkah 6:

Seleksi.

Langkah 7:

Setelah HGA mencapai batas generasi, *best parent* yang didapatkan digunakan untuk melakukan *testing* pada SVR.

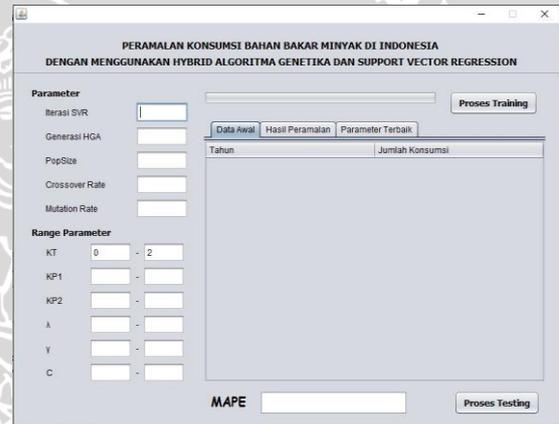
Langkah 8:

Lakukan perhitungan *error rate* setelah mendapatkan hasil peramalan.

5. IMPLEMENTASI

5.1 Halaman Training Data

Halaman proses *taining* digunakan untuk memasukkan inputan parameter Algoritma SVR dan HGA, batas – batas parameter yang digunakan, serta perolehan hasil peramalan yang telah diproses. Halaman *training* data dapat dilihat pada Gambar 5.



Gambar 5 Halaman Training Data

5.2 Halaman Testing Data

Halaman proses *testing* digunakan untuk memasukkan nilai parameter yang optimal serta untuk mendapatkan hasil peramalan. Halaman *testing* data dapat dilihat pada Gambar 6.

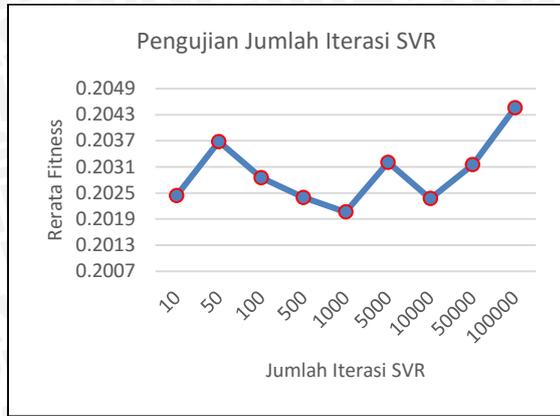


Gambar 6 Halaman Testing Data

6. PENGUJIAN DAN ANALISIS

a. Pengujian Jumlah Iterasi SVR

Uji coba banyaknya jumlah iterasi SVR digunakan untuk mengetahui jumlah iterasi yang paling optimal pada SVR untuk memberikan hasil peramalan yang paling baik. Uji coba SVR digunakan 9 variasi iterasi diantaranya 10, 50, 100, 500, 1000, 5000, 10000, 50000 dan 100000.

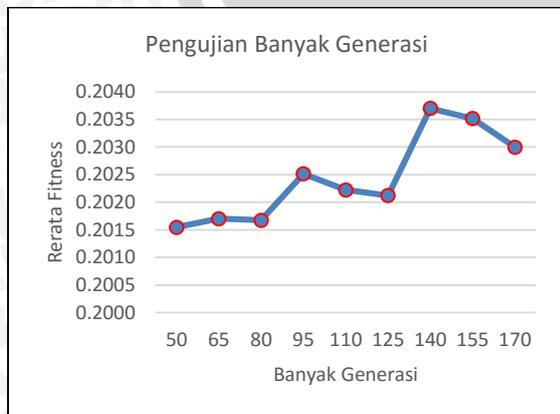


Gambar 7 Grafik Hasil Pengujian Iterasi SVR

Berdasarkan grafik hasil pengujian pada Gambar 7 rerata *fitness* paling besar didapatkan pada iterasi SVR 100000. Tentunya semakin banyak iterasi SVR yang digunakan, nilai α dan α^* yang lebih baik dan menghasilkan nilai peramalan yang baik. Namun semakin banyak jumlah iterasi maka akan semakin lama waktu komputasinya.

b. Pengujian Jumlah Generasi HGA

Untuk pengujian pada jumlah generasi HGA yang digunakan adalah 50, 65, 80, 95, 110, 125, 140, 155, dan 170. Berdasarkan grafik hasil pengujian pada Gambar 8 didapatkan nilai paling optimal untuk peramalan pada generasi sebanyak 140. Semakin banyaknya generasi nilai *fitness* yang dihasilkan akan cenderung sama sehingga terjadi konvergensi, apabila terus dilakukan penambahan generasi tidak akan menghasilkan solusi yang lebih baik dan cenderung akan membuang waktu.

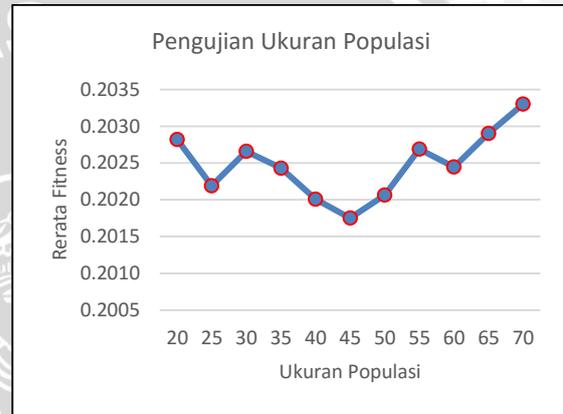


Gambar 8 Grafik Uji Generasi HGA

c. Pengujian Ukuran Populasi Optimal

Untuk pengujian pada ukuran populasi optimal yang digunakan adalah 20, 25, 30, 35, 40, 45, 50, 55, 60, 65 dan 70. Berdasarkan grafik hasil pengujian pada Gambar 9 didapatkan nilai paling optimal untuk peramalan pada populasi sebanyak 70 karena pada ukuran populasi sebesar 70 dengan kelipatan 5 pada ukuran populasi selanjutnya tidak mengalami kenaikan nilai rata-rata *fitness* dan cenderung stabil.

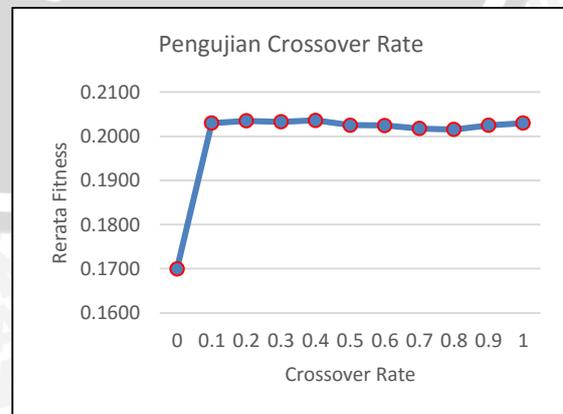
Jumlah populasi berpengaruh terhadap perubahan nilai *fitness*, karena populasi tidak cukup menyediakan jumlah sample untuk sebagian hyperplane. Semakin besar ukuran populasi maka akan menghasilkan nilai *fitness* semakin besar juga, namun setelah batas tertentu (pada kasus ini sebesar 70) kenaikan yang didapatkan semakin tidak signifikan.



Gambar 9 Grafik Uji Populasi

d. Pengujian Crossover Rate

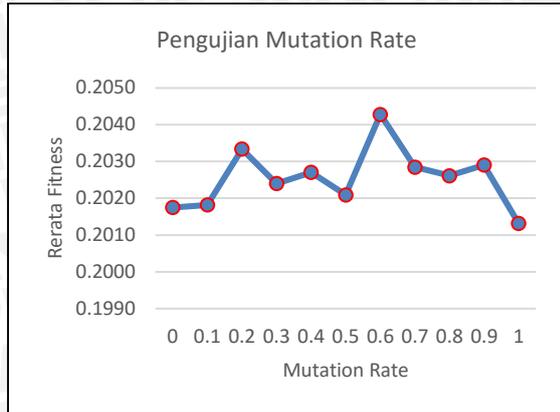
Untuk pengujian pada uji coba crossover rate yang digunakan adalah 0 hingga 1 dengan kelipatan 0.1. Berdasarkan grafik hasil pengujian pada Gambar 10 didapatkan nilai paling optimal untuk peramalan pada *crossover rate* sebesar 0.4. *Crossover rate* yang terlalu tinggi dapat mengakibatkan algoritma genetika tidak mampu memperluas area pencarian. Hal ini dapat mengakibatkan kromosom yang dihasilkan pada generasi berikutnya tidak mengalami kenaikan nilai *fitness*.



Gambar 10 Grafik Uji Crossover Rate

e. Pengujian Mutation Rate

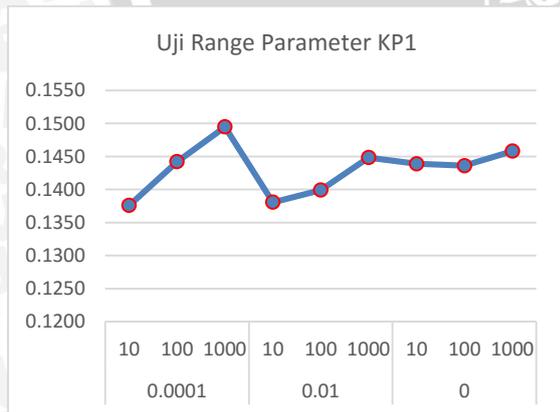
Untuk pengujian pada uji coba mutation rate yang digunakan adalah 0 hingga 1 dengan kelipatan 0.1. Berdasarkan grafik hasil pengujian pada Gambar 11 didapatkan nilai paling optimal untuk peramalan pada *mutation rate* sebesar 0.6. *Mutation rate* yang terlalu tinggi dapat mengakibatkan algoritma genetika akan bekerja seperti random *search* dan tidak mampu mengeksplorasi daerah pencarian secara efektif.



Gambar 11 Grafik Uji Mutation Rate

f. Pengujian Range Parameter KP1

Untuk pengujian pada nilai range parameter yang digunakan 0.0001-10, 0.0001-100, 0.0001-1000, 0.01-10, 0.01-100, 0.01-1000, 0-10, 0-100, dan 0-1000. Berdasarkan grafik hasil pengujian pada Gambar 12 didapatkan nilai paling optimal untuk peramalan pada range 0.0001 - 1000. *KP1* memberikan pengaruh terhadap polynomial kernel sebagai parameter yang dapat memberikan pengaruh meningkatkan kualitas data yang digunakan agar mendapatkan nilai peramalan yang baik.

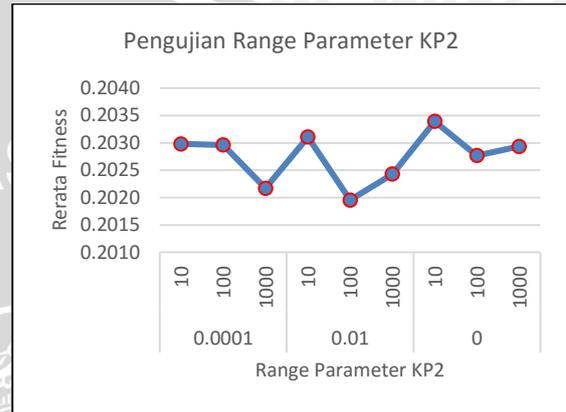


Gambar 12 Grafik Uji Range Parameter KP1

g. Pengujian Range Parameter KP2

Untuk pengujian pada nilai range parameter yang digunakan 0.0001-10, 0.0001-100, 0.0001-1000, 0.01-10, 0.01-100, 0.01-1000, 0-10, 0-100, dan 0-1000. Berdasarkan grafik hasil pengujian pada Gambar 13 didapatkan nilai paling optimal untuk

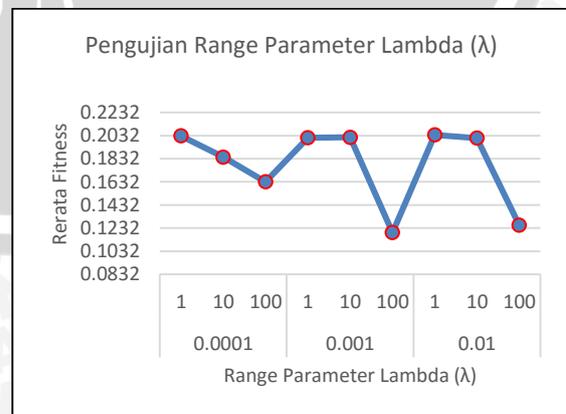
peramalan pada range 0-10. *KP2* memberikan pengaruh terhadap polynomial kernel sebagai degree dan terhadap RBF kernel sebagai σ . Degree pada polynomial dapat meningkatkan fleksibilitas pada batas deviasi yang berujung pada nilai *error rate* yang dihasilkan. Sedangkan σ menentukan kedekatan antara 2 titik sehingga dapat menentukan tingkat konsistensi terhadap batas deviasi. Nilai degree dan σ yang terlalu besar bias mengakibatkan sulitnya menemukan tingkat konsistensi terhadap batas deviasi.



Gambar 13 Grafik Uji Range Parameter KP2

h. Pengujian Range Parameter λ

Untuk pengujian pada nilai range parameter yang digunakan 0.0001-1, 0.0001-10, 0.0001-100, 0.001-1, 0.001-10, 0.001-100, 0.01-1, 0.01-10, dan 0.01-100. Berdasarkan grafik hasil pengujian pada Gambar 14 didapatkan nilai paling optimal untuk peramalan pada range 0.01 - 1. Semakin besar nilai dari λ akan memberikan nilai evaluasi yang baik pada regresi, namun waktu komputasi yang dibutuhkan akan lebih lama karena lambatnya kecepatan konvergensi dan proses learning yang kurang stabil. Hal ini dikarenakan pengaruh nilai λ dapat meningkatkan input space sehingga tidak akan terjadi konvergensi dini dan menjaga proses learning agar tetap stabil.

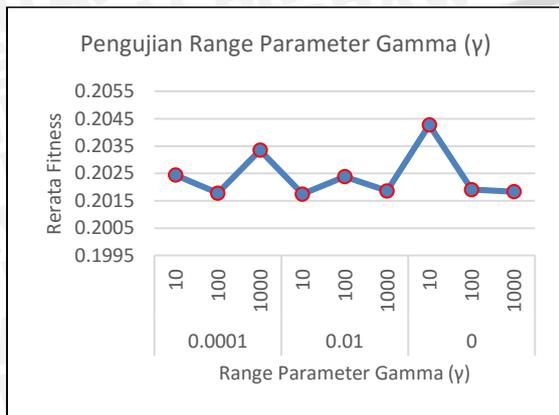


Gambar 14 Grafik Uji Range Parameter λ

i. Pengujian Range Parameter γ



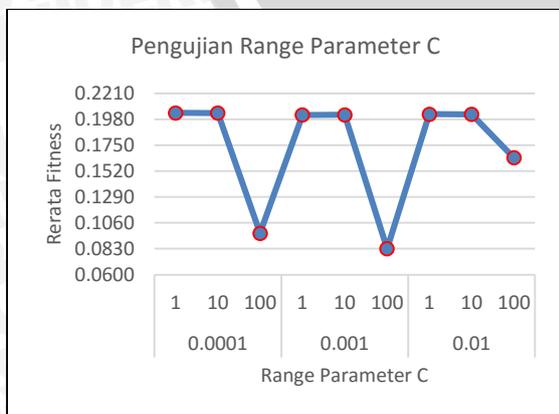
Untuk pengujian pada nilai range parameter yang digunakan 0.0001-10, 0.0001-100, 0.0001-1000, 0.01-10, 0.01-100, 0.01-1000, 0-10, 0-100, dan 0-1000. Berdasarkan grafik hasil pengujian pada Gambar 15 didapatkan nilai paling optimal untuk peramalan pada range 0 - 10. Semakin kecil nilai γ , maka proses learning akan berlangsung lebih lama namun hasil yang didapat lebih konvergen. Hal ini dikarenakan pengaruh nilai γ yang mengontrol kecepatan proses learning dalam mencapai hasil yang konvergen^[14].



Gambar 15 Grafik Uji Range Parameter γ

j. Pengujian Range Parameter C

Untuk pengujian pada nilai range parameter yang digunakan 0.0001-1, 0.0001-10, 0.0001-100, 0.001-1, 0.001-10, 0.001-100, 0.01-1, 0.01-10, dan 0.01-100. Berdasarkan grafik hasil pengujian pada Gambar 16 didapatkan nilai paling optimal untuk peramalan pada range 0.0001 - 1. Nilai C yang ada pada range tersebut terbukti menghasilkan nilai paling optimal dibandingkan dengan batas lainnya. Konstanta C dijadikan sebagai variabel yang menampung nilai pelanggaran toleransi berupa batas atas deviasi terhadap fungsi regresi^[14], semakin tinggi nilai C yang didapat memberikan indikasi bahwa semakin jauh garis regresi yang dibentuk terhadap batas deviasi yang ada, sedangkan semakin kecil nilai C yang didapat menandakan garis regresi yang terbentuk semakin mendekati dengan batas deviasi yang ada.



Gambar 16 Grafik Uji Range Parameter C

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. Dalam penelitian ini terdapat 6 parameter yang dioptimasi menggunakan HGA diantaranya yaitu tipe kernel, nilai parameter kernel ke-1, nilai parameter kernel ke-2, nilai lambda, nilai gamma, dan nilai kompleksitas. Panjang data yang digunakan dalam SVR adalah sebanyak 45 data yang berisi data harga BBM dalam rentang waktu pertahun. Nilai optimal dari parameter tersebut akan didapatkan dari proses optimasi dengan metode *Hybrid Algoritma Genetika*. Selanjutnya nilai parameter yang dihasilkan akan digunakan untuk parameter metode *Support Vector Regression* sehingga akan dihasilkan nilai evaluasi peramalan.
2. Koefisien yang dihasilkan oleh sistem menghasilkan nilai error yang cukup rendah dan pada sistem ini algoritma HGA ini dapat memberikan solusi optimal dalam mengoptimasi peramalan harga BBM menggunakan metode *Support Vector Regression* yaitu dengan menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 2.8737 pada iterasi SVR sebesar 50 dengan parameter diantaranya $KT = 0$ yang merupakan linear kernel, $KP1 = 86.5562$, $KP2 = 31.842$, $\lambda = 1.841$, $\gamma = 73.312$, $C = 3.0701$.

7.2 SARAN

Untuk penelitian selanjutnya, peneliti dapat menambahkan tipe kernel dalam pemetaan data, selain itu pada penelitian selanjutnya bisa menggunakan metode SVR untuk *multitarget forecasting*.

DAFTAR PUSTAKA

- [1] A. P. Desvina and A. R. Siddiq, "Pendekatan Peramalan Tingkat Konsumsi Minyak Di Indonesia Dengan Menggunakan Metode Box-Jenkins," vol. 9, 2011.
- [2] C.-H. Wu, G.-H. Tzeng and R.-H. Lin, "A Novel hybrid genetic algorithm for kernel function and parameter optimization in support vector regression," 2009.
- [3] L. Pasolli, C. Notarnicola and L. Bruzzone, "Multi-Objective Parameter Optimization in Support Vector Regression: General Formulation and Application to the Retrieval of Soil Moisture From Remote Sensing Data," vol. 5, 2012.

- [4] E. Ying, "Application of Support Vector Regression Algorithm in Colleges Recruiting Students Prediction," pp. 173-176, 2012.
- [5] Amelia, R. Regasari and D. Priharsari, "Implementasi Hybrid Algoritma Genetika Untuk Penjadwalan Auditor Pada Audit Internal Mutu Universitas Brawijaya," vol. 4, 2014.
- [6] Sunoto, "Analisis Kebijakan Subsidi Bagi Nelayan Akibat Kenaikan Harga Bahan Bakar Minyak (Bbm)," vol. XVI, no. 1410-8828, pp. 57-66, 2006.
- [7] Farizal, A. Rachman and H. A. Rasyid, "Model Peramalan Konsumsi Bahan Bakar Jenis Premium Di Indonesia Dengan Regresi Linier Berganda," vol. 13, no. 1412-6869, 2014.
- [8] R. Alwee, S. M. H. Shamsuddin and R. Sallehuddin, "Hybrid Support Vector Regression and Autoregressive Integrated Moving Average Models Improved by Particle Swarm Optimization for Property Crime Rates Forecasting with Economic Indicators," vol. 2013, 2013.
- [9] T. Zhang, "An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods," 2001.
- [10] C.-H. Wu, G.-H. Tzeng, Y.-J. Goo and W.-C. Fang, "A real-valued genetic algorithm to optimize the parameters of support vector machine for predicting bankruptcy," p. 397-408, 2007.
- [11] C.-H. Wu, G.-H. Tzeng and R.-H. Lin, "A Novel Hybrid Genetic Algorithm For Kernel Function And Parameter Optimization in Support Vector Regression," 2009.
- [12] S. K. Patro and K. K. sahu, "Normalization: A Preprocessing Stage," 2015.
- [13] S. Makridakis and M. Hibon, "Evaluating Accuracy (or Error) Measure," 1995.
- [14] S. Vijayakumar and S. Wu, "Sequential Support Vector Classifiers and Regression," pp. 610-619, 1999.