

PERAMALAN HARGA BBM MENGGUNAKAN METODE *SUPPORT VECTOR REGRESSION* DENGAN *ANT COLONY OPTIMIZATION*

Yunastria Christine Irwanti¹, Imam Cholissodin², Achmad Ridok²

¹Mahasiswa, ²Dosen Pembimbing

Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya, Malang 65145, Indonesia

Email : yunastria.christine@gmail.com¹, imamcs@ub.ac.id², acridokb@ub.ac.id²

ABSTRAK

Perkembangan Ilmu Pengetahuan dan Teknologi (IPTEK) semakin pesat terutama dalam bidang ekonomi. Salah satu aspek dalam ekonomi yang sangat diperhatikan adalah mengenai harga BBM. Perilaku harga BBM yang *nonlinear* merupakan salah satu penyebab permasalahan di dalam dunia perekonomian. Penyebab permasalahan ini adalah siklus kenaikan harga BBM. Selama siklus ini terjadi, harga barang-barang dan juga makanan juga ikut mengalami kenaikan. Sementara itu, selama terjadi siklus penurunan harga BBM, harga barang dan makanan tersebut tidak mengalami penurunan harga atau tetap. Oleh karena itu, maka sebagian besar masyarakat menolak kenaikan harga BBM. Jika kenaikan harga BBM cukup tinggi, itu akan memberikan dampak yang sangat serius terhadap perilaku masyarakat dan kestabilan perekonomian di Indonesia. Ditinjau dari permasalahan tersebut, maka metode *Support Vector Regression* dapat digunakan untuk melakukan peramalan harga BBM dengan memanfaatkan data harga BBM beberapa tahun sebelumnya. Metode SVR dapat menghasilkan nilai *error rate* yang lebih baik jika dioptimasi dengan menggunakan *Ant Colony Optimization*. Hal tersebut terbukti sesuai dengan hasil pengujian yang dilakukan menggunakan data yang didapat dari website ESDM (<http://www.esdm.go.id>) berupa harga BBM dari tahun 2001 hingga 2012, berdasarkan hasil yang diperoleh pada penelitian kali ini metode SVR yang dioptimasi dengan ACO dapat menghasilkan NMSE yang cukup rendah dengan kisaran nilai sebesar 0.108 hingga 0.28.

Kata Kunci : *Support Vector Regression, Ant Colony Optimization, Harga BBM, NMSE*

ABSTRACT

Evolution of Science and Technology are really fast, especially in the field of economy. One main concern of economy is about the price of fuel oil. Nonlinear behavior of fuel oil prices is one of the causes of the problems in the world of economy. The causes of this problem is the increasing cycle of fuel oil price. During this cycle, the price of goods and foods will also increase as well. Meanwhile, during a decreasing cycle of fuel oil prices, the prices of goods and foods are stagnant. Therefore, the majority of the people reject the increasing of fuel oil price. If the increase in fuel oil price is high enough, it will give a very serious impact on people's behavior and the stability of the economy in Indonesia. Judging from these problems, the Support Vector Regression method can be used for forecasting the price of fuel oil by utilizing the data fuel oil prices in this recent years. SVR method can generate better error rate value if optimized by using Ant Colony Optimization. This is proved in accordance with the results of this tests performed using data obtained from the ESDM website (<http://www.esdm.go.id>) in the form of fuel prices from 2001 to 2012, based on the results obtained in the present study SVR optimized method with ACO can generate fairly low NMSE within a range of values from 0.108 up to 0.28.

Keywords: *Support Vector Regression, Ant Colony Optimization, Price of Fuel Oil, NMSE.*

1. PENDAHULUAN

1.1 Latar Belakang

Saat ini harga minyak dunia terus mengalami gejolak harga. Beberapa faktor penyebab terjadinya gejolak harga tersebut diantaranya adalah minimnya kapasitas cadangan minyak saat ini, meningkatnya permintaan akan minyak dunia, serta kekhawatiran atas ketidakmampuan meningkatkan daya produksi dari negara-negara produsen [SUP-14]. Minimnya kapasitas cadangan minyak saat ini merupakan salah satu dampak dari

peningkatan permintaan energy yang terjadi diseluruh dunia, termasuk di Negara Indonesia. Menurut proyeksi Badan Energi Dunia (*International Energy Agency-IEA*), hingga tahun 2030 permintaan energi dunia meningkat sebesar 45% dimana rata-rata setiap tahunnya mengalami peningkatan sebesar 1,6% dan sekitar 85% dari energi dunia tersebut dipasok dari bahan bakar fosil [CAR-11].

Di Negara Indonesia, bahan bakar minyak (BBM) merupakan bahan bakar yang jumlah konsumennya paling tinggi, hal ini didukung dengan data dari kementerian energi dan sumber daya mineral bahwa sejak tahun 2005 sampai 2011 pemakaian BBM mengalami peningkatan sebesar 32,32% [CAR-11]. Peningkatan ini terjadi karena BBM merupakan energi utama yang digunakan dalam kegiatan transportasi dan produksi industri [NAH-13]. Oleh karena itu, lonjakan harga minyak dunia menimbulkan dampak yang besar bagi perekonomian di Indonesia. Salah satu dampaknya yaitu terjadinya kenaikan harga BBM dan kenaikan inflasi yang cukup tinggi. Kedua hal ini sangat mempengaruhi kondisi perekonomian Indonesia [PAR-14].

Perilaku harga BBM yang nonlinear merupakan salah satu penyebab permasalahan di dalam dunia perekonomian. Hal ini dikarenakan, pada saat terjadi siklus kenaikan harga BBM maka semua barang dan bahan-bahan pokok pangan juga akan mengalami kenaikan harga. Sedangkan pada saat terjadi siklus penurunan harga BBM, harga barang dan bahan-bahan pokok pangan tersebut tidak mengalami penurunan harga. Oleh karena itu, maka sebagian besar masyarakat keberatan apabila terjadi kenaikan harga BBM. Kenaikan harga BBM yang cukup tinggi, akan memberikan dampak yang sangat serius terhadap perilaku masyarakat dan kestabilan perekonomian di Indonesia. Beberapa upaya yang telah dilakukan pemerintah dalam menghadapi kenaikan harga BBM ini diantaranya, dengan mengeluarkan kebijakan program Bantuan Langsung Tunai bagi masyarakat miskin atau golongan tidak mampu. Akan tetapi, upaya pemerintah tersebut dipandang kurang efektif dikarenakan sebagian besar dana BLT tidak sampai pada orang yang tepat. Oleh karena itu, seiring dengan berlakunya kenaikan harga BBM, hendaknya dibuat suatu pemodelan untuk peramalan harga BBM di Indonesia. Hal ini bertujuan agar masyarakat dan pemerintah mampu menyeimbangkan kenaikan harga BBM dengan jumlah konsumsi BBM, sehingga kondisi perekonomian Indonesia dapat tetap stabil.

Terdapat beberapa penelitian yang membahas mengenai peramalan harga Minyak. Penelitian sebelumnya yang dilakukan oleh Bao (2011) menunjukkan bahwa algoritma *Support Vector Regression* (SVR) dapat digunakan untuk peramalan terhadap harga minyak mentah. Melalui penelitiannya, Bao membuktikan bahwa nilai MAPE peramalan harga minyak mentah menggunakan SVR mengalami penurunan dari 37,1% menjadi 59% [BAO-11].

Support Vector Regression merupakan pengembangan SVM untuk kasus regresi. Tujuan dari SVR adalah untuk menemukan sebuah fungsi

sebagai suatu *hyperplane* (garis pemisah) berupa fungsi regresi yang sesuai dengan semua input data serta meminimalisasi nilai *error* [SEP-15]. Pada penelitian yang telah dilakukan sebelumnya, metode SVR ini dapat dioptimalkan dengan *Ant Colony Optimization* (ACO) untuk mendapatkan nilai evaluasi yang lebih baik. Algoritma *Ant Colony Optimization* (ACO) merupakan suatu model untuk pemecahan masalah optimasi dalam pencarian *cost path* minimum, sehingga dapat meningkatkan kinerja SVR dengan lebih baik. Metode SVR-ACO pernah digunakan untuk penyelesaian Gas Bearing Capacity Forecasting, penelitian ini dilakukan oleh Sun (2010) menunjukkan bahwa forecasting *error* SVR-ACO lebih kecil dibanding dengan forecasting BP Neural Network yaitu 0.0167 : 0.0294 [SUN-10].

Berdasarkan beberapa penelitian di atas, maka pada skripsi ini penulis mengusulkan peramalan harga BBM menggunakan metode *Support Vector Regression* yang dioptimasi dengan *Ant Colony Optimization*. Implementasi yang akan dilakukan adalah memadukan metode regresi yaitu SVR untuk melakukan forecasting harga BBM, sedangkan metode ACO digunakan sebagai metode untuk melakukan pengoptimalan terhadap koefisien – koefisien yang terdapat pada SVR. Harapannya, implementasi kedua metode ini dapat memberikan peramalan yang baik untuk harga BBM sehingga dapat digunakan sebagai bahan masukan dan pertimbangan bagi masyarakat dalam membuat kebijakan penjualan serta evaluasi dalam pengolahan sumber daya perusahaan untuk memperoleh keuntungan maksimum. Dengan begitu, maka perekonomian Indonesia dapat tetap stabil.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang di atas, maka dapat dirumuskan permasalahan sebagai berikut :

1. Bagaimana mengimplementasikan algoritma *Ant Colony Optimization* (ACO) untuk optimasi peramalan harga BBM menggunakan *Support Vector Regression* (SVR) ?
2. Berapa tingkat akurasi peramalan harga BBM menggunakan metode *Support Vector Regression* (SVR) dengan *Ant Colony Optimization* (ACO)?

1.3 Batasan Masalah

Batasan masalah yang dijadikan sebagai pedoman dalam pelaksanaan penelitian ini adalah sebagai berikut :

1. Metode yang dipakai adalah *Support Vector Regression* (SVR) yang dioptimalkan dengan metode *Ant Colony Optimization* (ACO).

2. Obyek yang digunakan adalah harga BBM di Indonesia.
3. Data yang dibuat acuan adalah harga BBM 12 tahun terakhir, yaitu dari tahun 2001 – 2012 yang dibuat dalam bulanan. Data tersebut didapat dari <http://www.esdm.go.id>
4. Output yang dihasilkan oleh sistem adalah *value forecasting error*, dengan asumsi semakin kecil *value forecasting error* maka hasil peramalan data tersebut semakin baik.

1.4 Tujuan

Tujuan yang ingin dicapai dari pembuatan sistem ini adalah sebagai berikut :

1. Mengimplementasikan algoritma *Ant Colony Optimization* (ACO) untuk optimasi peramalan harga BBM menggunakan metode *Support Vector Regression* (SVR).
2. Menentukan tingkat akurasi peramalan harga BBM menggunakan metode *Support Vector Regression* (SVR) dengan *Ant Colony Optimization* (ACO).

1.5 Manfaat

Manfaat yang ingin dirasakan dari pembuatan sistem ini adalah sebagai berikut:

1. Sebagai dasar membuat kebijakan penjualan, bahan masukan, evaluasi dalam pengolahan sumber daya perusahaan untuk memperoleh keuntungan maksimum.
2. Memaksimalkan pendistribusian BBM serta membantu pemerintah dalam memutuskan kebijakan kenaikan harga BBM ke depannya.

2. TINJAUAN PUSTAKA

2.1 BBM

Harga minyak dunia saat ini terus mengalami gejolak harga. Lifting saat ini pada kisaran hanya 898 ribu barel per hari, sangat jauh dari target. Pemerintah harus kerja keras untuk tahun ini, apalagi harga minyak mentah Indonesia (ICP) masih berada di kisaran 110 dolar per barel, jauh di atas asumsi APBN 2012 yang hanya 90 dolar per barel. Harga minyak mentah dunia kembali hangat dibicarakan. Maklum, dalam beberapa hari terakhir, harga "emas hitam" (istilah minyak mentah) terus mengalami fluktuasi. Harga minyak di pasar global sudah menyentuh 90 dolar AS per barel, bahkan pasar memperkirakan harganya akan menembus 100 dolar AS per barel [HAR-10].

Banyak faktor penyebab gejolak harga tersebut. Di antaranya, minimnya kapasitas cadangan minyak saat ini, dan meningkatnya permintaan akan minyak dunia, serta kekhawatiran atas ketidakmampuan meningkatkan daya produksi dari negara-negara produsen. Dengan adanya situasi tersebut, pemerintah Indonesia dalam upaya meminimalkan subsidi BBM yang sangat besar, mengeluarkan kebijakan. Kebijakan tersebut yaitu

dengan meningkatkan harga jual BBM sehingga dapat menurunkan anggaran subsidi BBM dalam negeri. Pada tahun 2013 pengumuman kenaikan harga jual BBM telah dilakukan pada tanggal 21 Juni 2013. Pengumuman kenaikan harga BBM tahun 2013 dirasakan berbeda dengan pengumuman kenaikan harga BBM tahun sebelumnya. Pada tahun 2013 ini, peningkatan harga jual BBM cukup besar, yakni kurang lebih 50% dari harga sebelumnya [SUP-14].

2.2 Algoritma *Support Vector Regression* (SVR)

Support Vector Regression (SVR) merupakan pengembangan SVM untuk kasus regresi yang diperkenalkan oleh Hong (2010). SVM adalah sistem pembelajaran yang menggunakan ruang hipotesis berupa fungsi-fungsi linier dalam sebuah ruang fitur (*feature space*) berdimensi tinggi, dilatih dengan algoritma pembelajaran yang didasarkan pada teori optimasi dengan mengimplementasikan learning bias. Konsep SVM menggunakan konsep ide ϵ -insensitive loss function. SVM dapat digeneralisasi untuk melakukan pendekatan fungsi yang dikenal dengan SVR. Konsep SVM menggunakan hyperplane tunggal pada ruang berdimensi banyak yang pada akhirnya partisi-partisi tersebut dapat diselesaikan secara tidak linier. Hyperplane yang optimum dapat diselesaikan dengan metode quadratic programming. Konsep SVR didasarkan pada risk minimization, yaitu untuk mengestimasi suatu fungsi dengan cara meminimalkan batas atas dari *generalization error*, sehingga SVR mampu mengatasi *overfitting* [YAS-14]. *Overfitting* merupakan perilaku data yang pada saat fase *Training* menghasilkan nilai akurasi peramalan hampir sempurna sama dengan nilai aktual data. Tujuan dari SVR adalah untuk menemukan sebuah fungsi $f(x)$ sebagai suatu hyperplane (garis pemisah) berupa fungsi regresi yang mana sesuai dengan semua input data dengan sebuah *error* ϵ dan membuat ϵ seminimal mungkin [MEE-13].

2.2.1 Formula Alternatif untuk Bias

Nilai bias dapat diformulasikan ke dalam bentuk lain yaitu dengan menggunakan penambahan dimensi untuk vektor masukan tambahan didefinisikan sebagai berikut [VIJ-99].

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

Terdapat perbedaan pendefinisian Lagrange multiplier (dan) pada fungsi tidak linier yang digunakan Vijayakumar (1999) dan Smola & Scholkopf (2004) yang ditunjukkan pada Persamaan 2.34 dan 2.36. Hal ini terjadi karena bergantung pada inialisasi letak dan pada grafik fungsi *loss* SVR.

2.2.2 Algoritma Sequential Learning

Pada setiap perhitungan fungsi SVR, terdapat proses sequential learning. Algoritma *sequential* untuk regresi dapat dilihat di bawah ini [VIJ-99] :

$[R]_{ij}$ = merupakan matriks *kernel*.

E_i = merupakan nilai *error*.

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^* = merupakan suatu nilai formulasi

α_i = merupakan suatu nilai formulasi

C = merupakan nilai kompleksitas

ε = merupakan nilai deviasi

λ = merupakan set data *training*

x_i = merupakan data ke- i

x = merupakan data

Berikut proses *sequential learning* dalam perhitungan fungsi SVR :

1. Inisialisasi $\alpha_i = 0, \alpha_i^* = 0$. Hitung

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

untuk $i, j = 1, \dots, n$

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

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

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

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

$$\alpha_i^* = \alpha_i^* + \delta\alpha_i^*$$

$$\alpha_i = \alpha_i + \delta\alpha_i$$

3. Kembali pada langkah kedua, sampai pada kondisi iterasi maksimum atau

$$\max(|\delta\alpha_i|) < \varepsilon \text{ dan } \max(|\delta\alpha_i^*|) < \varepsilon$$

4. Menghitung fungsi regresi dengan menggunakan rumus yang sudah dijabarkan diatas.
5. Selesai

2.3 Algoritma Ant Colony Optimization (ACO)

Algoritma semut diperkenalkan oleh Moysen dan Manderick dan secara meluas dikembangkan oleh Marco Dorigo (Waliprana, 2009). *Ant Colony Optimization* (ACO) diadopsi dari perilaku koloni semut yang dikenal sebagai sistem semut. Tahapan utama dari ACO adalah sebagai berikut [KUN-12]:

1. Inisialisasi parameter yang dimiliki ACO
 - a. Intensitas *pheromone* (τ_{ij}).
 - b. Tetapan siklus *ant* (q_0).

- c. Tetapan pengendali intensitas visibilitas (β), nilai $\beta \geq 0$.
- d. Tetapan pengendali *pheromone* (α), nilai $\alpha \geq 0$.
- e. Jumlah *ants* (m).
- f. Jumlah *node ant*
- g. Tetapan penguapan *pheromone* (ρ), nilai ρ harus > 0 dan < 1 .
- h. Jumlah siklus maksimum (NC_{max}).

2. Memberikan nilai bobot (w) untuk jarak, *node* dan jumlah *ant*.
3. Menghitung visibilitas antar *node*
4. Menentukan *node* selanjutnya yang akan dituju, ulangi proses sampai *node* tujuan tercapai.
5. Apabila telah memilih *node* yang dituju, *node* tersebut disimpan ke dalam tabu *list* untuk menyatakan bahwa *node* tersebut telah menjadi bagian dari membangun solusi. Setelah itu intensitas *pheromone* di sisi tersebut diubah, perubahan *pheromone* tersebut dinamakan perubahan *pheromone* local. Aturan transisi kembali dilakukan sampai *node* tujuan tercapai.
6. Apabila *node* tujuan telah dicapai, panjang rute, banyaknya lubang, banyaknya tikungan dan kepadatan dari masing-masing *ants* akan dilakukan perangkingan untuk mencari *path* yang terbaik
7. Pembaruan *pheromone* pada *node-node* yang termuat dalam *path* terbaik tersebut dinamakan perubahan *pheromone* global.
8. Pengosongan tabu *list*, tabu *list* perlu dikosongkan untuk diisi lagi dengan urutan *node* yang baru. Algoritma diulang lagi dari langkah 2 dengan harga parameter intensitas *pheromone* yang sudah di perbarui.
9. Setelah semua proses telah diuji (jumlah siklus maksimum sudah terpenuhi) maka akan di dapatkan *path* terbaik.

2.4 SVR-ACO

Berikut langkah-langkah metode SVR-ACO [LIX-10] :

1. Tentukan parameter SVR yang akan dioptimasi dengan metode ACO.
2. Tentukan batas minimum dan maksimum setiap parameter yang telah dipilih.
3. Tentukan jumlah *ant*
4. Tentukan banyaknya *node ant* sebagai parameter bit absis dan *range* ordinat.
5. Inisialisasi nilai setiap parameter ACO
6. Tentukan *node* setiap *ant* :
 - a. Tentukan posisi *node ant* pertama secara acak (*random*) sebagai nilai r .
 - b. Tentukan *next node* (nilai u) :
 - Jika $q \leq q_0$,
 - $\arg \max\{[\tau(r, u)]^\alpha \cdot [\tau(r, u)]^\beta\}$
 - Jika $q > q_0$, Tentukan nilai S



q merupakan nilai acak yang diambil antara nilai 0 sampai 1, sedangkan α , β dan q_0 nilainya telah diinisialisasi dari awal oleh user yaitu $0 \leq q_0 \leq 1$. Nilai S ditentukan secara acak sesuai dengan range yang telah ditentukan, nilai S digunakan untuk dasar perhitungan distribusi dibawah ini :

- Jika $S \in J(r)$,

$$P(r,u) = \frac{[\tau(r,u)]^\alpha \cdot [\tau(r,u)]^\beta}{\sum_{u \in J(r)} [\tau(r,u)]^\alpha \cdot [\tau(r,u)]^\beta}$$

- Jika $S \notin J(r)$, 0

Strategi seleksi persamaan diatas dikenal dengan istilah seleksi "Roulette Wheel". Nilai akhir dari seleksi tersebut yaitu nilai maksimum dari perhitungan jarak (*prob*) seluruh *node*, dengan cara membangkitkan satu nilai acak untuk penentuan nilai maksimum dari *probCum*. Dimana nilai *probCum* merupakan jumlah *komulatif* dari nilai *prob*.

- Update nilai $\tau(r,u)$ local :

$$\tau(r,u) = (1 - \rho) \cdot (\tau(r,u)) + \rho \tau_0$$

- Setelah mendapatkan *node ant* baru, maka *node ant* tersebut menjadi nilai r berikutnya. Ulangi langkah b sampai seluruh *node ant* terlewati.
- Setelah *ant* pertama menemukan seluruh *node ant*, maka *range node ant* yang terpilih tersebut dikonversi kedalam parameter SVR yaitu σ, C dan ϵ .
 - Lakukan perhitungan SVR, sampai dengan mendapatkan nilai NMSE.
 - Ulangi langkah 6, 7 dan 8 sampai dengan sejumlah *ant* yang telah diinisialisasikan
 - Setelah mendapatkan nilai NMSE seluruh *ant*, tentukan nilai minimum NMSE
 - Lakukan *update* nilai $\tau(r,u)$ global, pada *ant* yang memiliki nilai NMSE paling kecil:

$$\tau(r,u) = (1 - \delta) \cdot \tau(r,u) + \delta \cdot \Delta \tau(r,u)$$
 Dimana :
 - Jika $(r,u) \in \text{global best tour}$, maka

$$\Delta \tau(r,u) = \frac{1}{L_{gb}}$$
 - Jika $(r,u) \notin \text{global best tour}$, maka

$$\Delta \tau(r,u) = 0$$
 - Ulangi langkah 6 sampai dengan 11. Jika sudah memenuhi syarat $NCmax$, maka tentukan nilai minimum dari nilai NMSE setiap *path node ant* pada setiap iterasi.

- Nilai maksimum tersebut merupakan *node ant* terbaik yang dapat digunakan metode SVR untuk menghasilkan suatu fungsi regresi.

2.5 Metode Kernel

Banyak teknik data mining atau *machine learning* yang dikembangkan dengan asumsi kelinieran, sehingga algoritma yang dihasilkan terbatas untuk kasus-kasus yang linier. Dengan metode *kernel (Kernel Trick)* suatu data di *input space* dipetakan ke *feature space* dengan dimensi yang lebih tinggi melalui [RAJ-13]. *Kernel Radial Basis Function (RBF)* :

$$K(x, y) = \exp\left(-\left(\frac{1}{2\sigma^2}\right) \times \|x - y\|^2\right)$$

x dan y adalah pasangan dua data dari semua bagian data latih, sedangkan parameter c dan d merupakan konstanta [PIN-11].

2.6 Nilai Evaluasi

Nilai evaluasi merupakan nilai yang digunakan untuk mengetahui sejauh mana akurasi peramalan yang dihasilkan, selisih antara nilai ramalan dengan nilai *actual*, atau biasa disebut dengan *error rate*. Nilai *error rate* yang biasa digunakan adalah NMSE. NMSE merupakan sebuah metode untuk membandingkan rata-rata hasil prediksi dengan rata-rata nilai aktual. Semakin kecil nilai NMSE maka semakin kecil perbedaan antara nilai asli dengan nilai prediksi, sebaliknya semakin besar nilai NMSE maka semakin besar perbedaan antara nilai asli dengan nilai prediksi. Pendekatan ini berguna ketika ukuran atau besar variabel ramalan itu penting dalam mengevaluasi ketepatan ramalan [CHA-09]. NMSE mengindikasikan seberapa besar kesalahan dalam meramal yang dibandingkan dengan nilai nyata pada deret data. Metode NMSE digunakan untuk membandingkan ketepatan dari teknik yang sama atau berbeda dalam dua deret data yang sangat berbeda. Penjabaran rumus NMSE akan dijelaskan pada persamaan berikut :

$$NMSE = \frac{\sqrt{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2\right)}}{(x_{\max} - x_{\min})}$$

Keterangan :

- N merupakan banyaknya data
- x_i merupakan data asli ke- i
- \hat{x}_i merupakan data prediksi ke- i
- x_{\max} merupakan nilai terbesar dari x
- x_{\min} merupakan nilai terkecil dari x

3. METODOLOGI

Tahapan penelitian ini ditunjukkan pada Gambar 1. Diagram Alir Metode Penelitian seperti berikut ini :



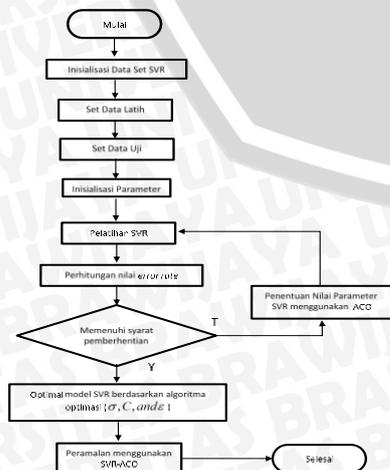
Gambar 1. Diagram Alir Metode Penelitian

3.2 Data Penelitian

1. Data yang digunakan dalam penelitian adalah daftar harga bahan bakar minyak (BBM) dalam negeri, kurang lebih 12 tahun terakhir mulai dari tahun 2001 sampai tahun 2012. Data tersebut didapatkan dari website resmi Kementerian Energi dan Sumber Daya Mineral (ESDM).
2. Data harga bahan bakar minyak (BBM) yang diolah adalah data harga bensin setiap bulan.

3.3 Perancangan Sistem

Alir perancangan sistem untuk sistem peramalan harga BBM menggunakan metode SVR-ACO ditunjukkan pada Gambar 2.



Gambar 2. Diagram Alir Sistem

3.4 Proses Perhitungan Manualisasi

• Inisialisasi Parameter ACO

Table 1. Parameter ACO

Jumlah Semut	Ordinate	NCmax	ρ	β	α	τ_{ij}	$q0$	δ
12	9	2	0.9	0.9	0.1	0.5	0.9	0.5

• Menentukan Node Ant

1. Inisialisasi Node Pertama (r), $node\ 1 = 7$
2. Menentukan Next Node (u), inisialisasi nilai q secara random dalam range 0 sampai 1, misal $q = 0.5$ dan next node = 5
3. Update Pheromone Local
 $\tau(r, u) = (1 - \rho)(\tau(r, u)) + \rho\tau_0$
 $\tau(7,5) = (1 - 0.9) \times 0.5 + (0.9 \times 0.5) = 0.5$
4. Update nilai r dengan nilai u , jadi nilai $r = 5$
5. Ulangi menentukan next node Ant sampai memenuhi batas maksimal jumlah ant
6. Update Pheromone Global
 $\tau(r, u) = (1 - \delta)\tau(r, u) + \delta\Delta\tau(r, u)$
 $\tau(7,5) = ((1 - 0.5) \times 0.345) + (0.5 \times (1/5.256520031)) = 0.2676$

• Konversi Nilai Node Ant

Node 1 sampai dengan Node 4 menjadi nilai $\sigma = 0.7548$
 Node 5 sampai dengan Node 8 menjadi nilai $C = 3269$
 Node 9 sampai dengan Node 12 menjadi nilai $\varepsilon = 0.1759$

• Inisialisasi Parameter SVR

Table 2. Parameter SVR

cLR	C	ε	γ	λ	σ
0.03	3269	0.1759	0.018293	0.8	0.7548

• Proses Sequential Learning

1. Inisialisasi nilai α_i dan α_i^* dengan nilai 0 sebanyak jumlah data latih.
2. Menghitung jarak antar data
 $\|x_3 - x_5\|^2 = (0.3571 - 0.5249)^2 + (0.4665 - 0.5951)^2 + (0.5249 - 0.5645)^2 + (0.5951 - 0.5873)^2 = 0.046345$
3. Menghitung Matriks R_{ij}
 $[R]_{3,5} = K(x_3, x_5) + \lambda^2 = \exp\left(-\frac{0.046344628}{2 \times (0.7548)^2}\right) + 0.8^2 = 1.600143$
4. Perhitungan nilai E .
5. Perhitungan nilai $\delta\alpha_i$ dan $\delta\alpha_i^*$
6. Pembaharuan nilai α_i^* dan α_i
7. Proses Perhitungan Model Regresi
 $f(x) = ((0.006386 - (0)) \times 1.64) + ((0.007669 - (0)) \times 1.5859) + ((0.007110 - (0)) \times 1.559218) + ((0.007526 - (0)) \times 1.5395) + ((0.006364 - (0)) \times 1.51881) = 0.29921376$

4. IMPLEMENTASI

Pada implementasi *user interface*, aplikasi akan dibuat 7 halaman yaitu halaman utama sistem, halaman setting variable *training*, halaman setting variable *testing*, halaman result *training*, halaman result *testing*, halaman manualisasi dan halaman grafik peramalan harga BBM.

4.1 Implementasi Halaman Utama



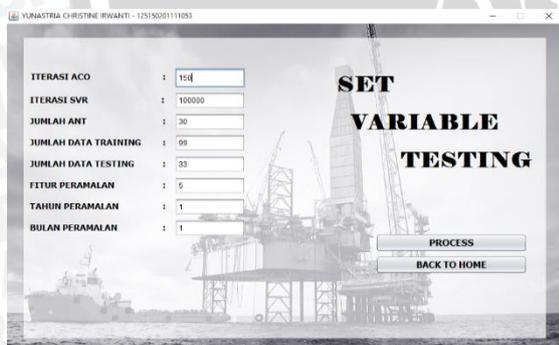
Gambar 3. Implementasi Halaman Utama

4.2 Implementasi Halaman Manualisasi



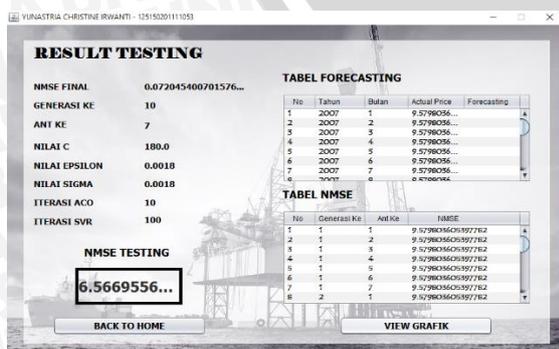
Gambar 4. Implementasi Halaman Manualisasi

4.3 Implementasi Halaman Setting Variabel Testing



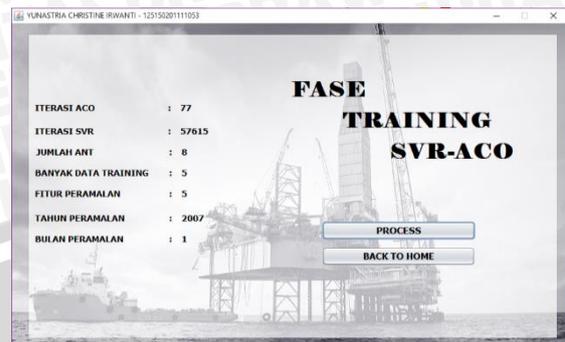
Gambar 5. Implementasi Halaman Setting Variable Testing

4.4 Implementasi Halaman Result Testing



Gambar 6. Implementasi Halaman Result Testing

4.5 Implementasi Halaman Setting Variable Training



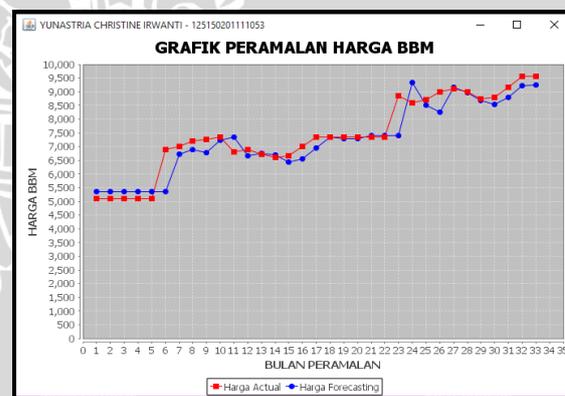
Gambar 7. Implementasi Halaman Setting Variable Training

4.6 Implementasi Halaman Result Training



Gambar 8. Implementasi Halaman Result Training

4.7 Implementasi Halaman Grafik Peramalan Harga BBM



Gambar 9. Implementasi Halaman Grafik Peramalan Harga BBM

5. PENGUJIAN DAN ANALISIS

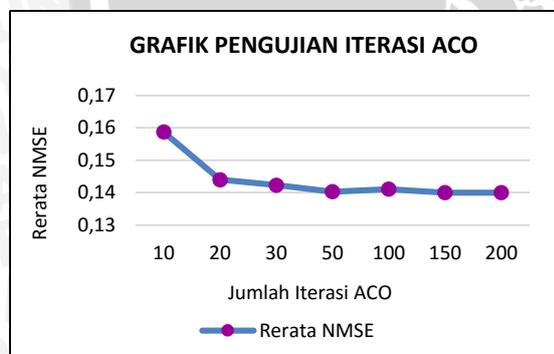
Pada sub bab ini akan dijelaskan mengenai pengujian aplikasi. Pengujian yang dilakukan berdasarkan skenario sebagai berikut :

1. Uji coba jumlah iterasi ACO
2. Uji coba jumlah *ant* pada ACO
3. Uji coba batas nilai parameter c yang dihasilkan ACO
4. Uji coba batas nilai parameter ϵ yang dihasilkan ACO

5. Uji coba batas nilai parameter σ yang dihasilkan ACO
6. Uji coba jumlah iterasi SVR
7. Uji coba terhadap variasi data *training*
8. Uji coba terhadap variasi data *testing*
9. Uji coba jumlah fitur data

5.1 Analisis Pengujian Terhadap Jumlah Iterasi ACO

Pada uji coba yang pertama dilakukan adalah uji coba jumlah iterasi ACO. Data yang digunakan dalam uji coba ini adalah harga BBM dari tahun 2001 – 2012 yang dibuat dalam data bulanan untuk meramalkan 31 bulan kedepannya. Untuk uji coba jumlah iterasi ACO ini digunakan iterasi maksimal SVR yaitu sebesar 1000 dengan jumlah *Ant* sebanyak 7 serta dengan batas dimensi σ antara 0.6 sampai 0.7. Analisa hasil NMSE yang diperoleh, pada iterasi ke 150 ACO mengalami konvergensi. Oleh karena itu pada iterasi 200 tidak ada perubahan nilai pada NMSE setiap percobaan, dengan begitu iterasi optimal dari ACO sebesar 150 iterasi. Selain dianalisa berdasarkan hasil rerata nilai NMSE setiap iterasi ACO, waktu komputasi juga menjadi salah satu acuan analisa dalam pengujian iterasi ACO. Untuk lebih jelasnya grafik rerata nilai NMSE yang dihasilkan pada uji coba jumlah iterasi ACO dapat dilihat pada Gambar 10 berikut ini :

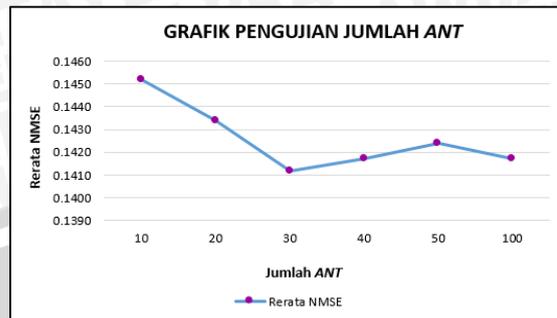


Gambar 10. Grafik Pengujian Iterasi ACO

5.2 Analisis Pengujian Terhadap Jumlah *Ant*

Pengujian jumlah *ant* pada ACO dilakukan sebanyak enam variasi jumlah *ant*, setiap variasi data dilakukan sepuluh kali percobaan. Analisa hasil dari uji coba jumlah *ant*, adalah semakin banyak jumlah *ant* belum pasti menghasilkan nilai permalan yang lebih baik. Akan tetapi, terdapat *range* jumlah *ant* tertentu yang dapat menghasilkan nilai yang lebih baik. Berdasarkan grafik hasil uji coba jumlah *ant* pada ACO pada Gambar 11, rerata nilai NMSE terkecil didapatkan dari jumlah *ant* sebanyak 30. Pada jumlah tersebut nilai rerata NMSE yang dihasilkan sebesar 0.1412. Hasil Uji

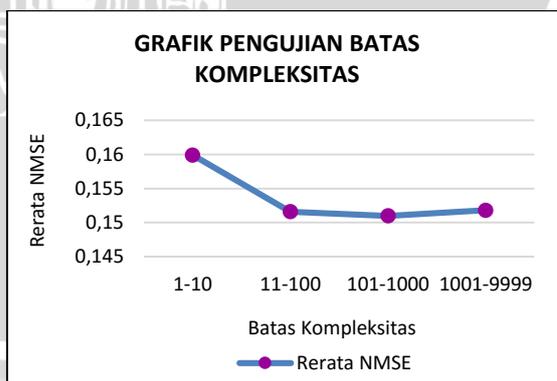
Coba Jumlah Iterasi ACO dapat diamati pada Gambar 11 berikut ini :



Gambar 11. Grafik Pengujian Jumlah *Ant*

5.3 Analisis Pengujian Terhadap Batas Nilai Parameter *C*

Pengujian batas nilai parameter kompleksitas dilakukan sebanyak empat variasi batasan, setiap variasi batasan dilakukan sebanyak sepuluh kali percobaan. Analisa hasil dari uji coba batas nilai parameter *C* adalah pada *range* 101 sampai dengan 1000 parameter *C* dapat menghasilkan nilai yang lebih baik. Berdasarkan grafik hasil uji coba batas nilai parameter kompleksitas pada Gambar 12, rerata nilai NMSE terkecil didapatkan pada batas antara 101 sampai dengan 1000. Pada batas tersebut nilai rerata NMSE yang dihasilkan adalah sebesar 0.151, hasil ini menunjukkan bahwa batas yang ideal untuk nilai parameter kompleksitas agar dapat menghasilkan nilai permalan terbaik yaitu pada batas antara 101 sampai dengan 1000. Untuk lebih jelasnya grafik rerata nilai NMSE yang dihasilkan pada uji batas nilai parameter kompleksitas dapat dilihat pada Gambar 12 berikut ini :

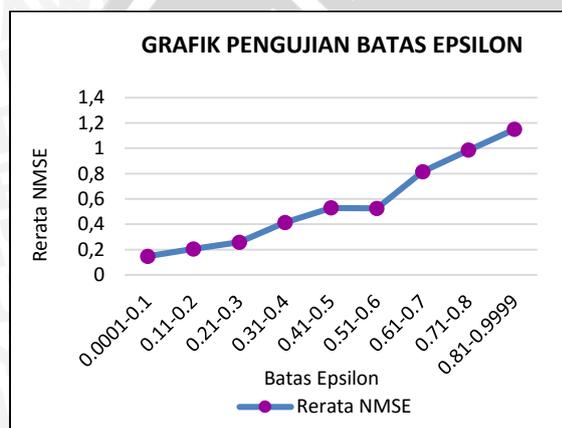


Gambar 12. Grafik Pengujian Batas Kompleksitas

5.4 Analisis Pengujian Terhadap Batas Nilai Parameter ϵ

Pengujian batas nilai parameter *epsilon* dilakukan sebanyak sembilan variasi batasan, setiap variasi batasan dilakukan sebanyak sepuluh kali percobaan. Berdasarkan grafik hasil uji coba

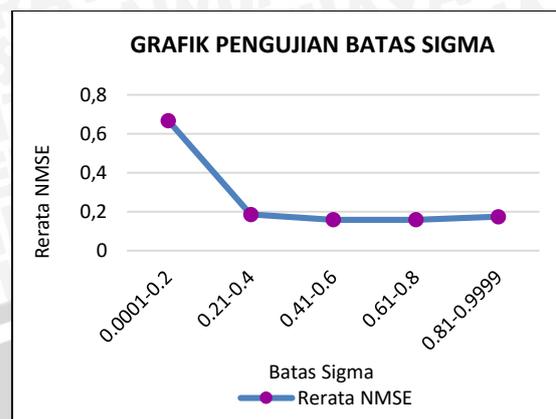
batas nilai parameter *epsilon* pada Gambar 13, rerata nilai NMSE terkecil didapatkan pada batas antara 0.0001 sampai dengan 0.1. Pada batas tersebut nilai rerata NMSE yang dihasilkan adalah sebesar 0.1471, hasil ini menunjukkan bahwa batas nilai parameter *epsilon* yang ideal agar dapat menghasilkan nilai NMSE yang terbaik yaitu pada batas antara 0.0001 sampai dengan 0.1. Selain itu, pada grafik hasil uji coba kali ini juga dapat disimpulkan bahwa hasil rerata nilai NMSE yang dihasilkan berbanding lurus dengan besar batas nilai parameter *epsilon*. Semakin besar batas nilai parameter *epsilon* maka rerata nilai NMSE yang dihasilkan juga semakin besar, hal ini ditunjukkan dengan pola grafik hasil uji coba pada Gambar 13 dimana pola grafik rerata nilai NMSE yang dihasilkan linear naik. Untuk lebih jelasnya grafik rerata nilai NMSE yang dihasilkan pada uji batas nilai parameter *epsilon* dapat dilihat pada Gambar 13 berikut ini :



Gambar 13. Grafik Pengujian Batas Epsilon

5.5 Analisis Pengujian Terhadap Batas Nilai Parameter σ

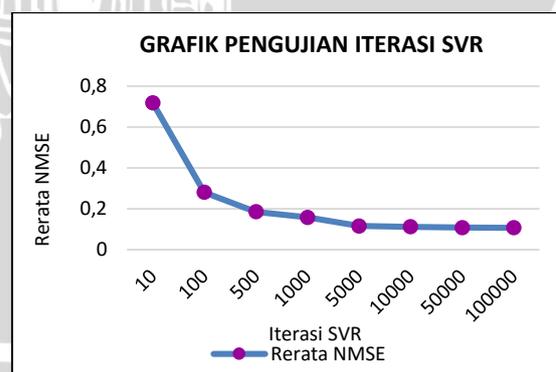
Pengujian batas nilai parameter *sigma* dilakukan sebanyak lima variasi batasan, setiap variasi batasan dilakukan sebanyak sepuluh kali percobaan. Analisa hasil dari uji coba batas nilai parameter ϵ adalah pada *range* 0.41 sampai dengan 0.6 parameter ϵ dapat menghasilkan nilai yang lebih baik. Berdasarkan grafik hasil uji coba batas nilai parameter sigma pada Gambar 14, rerata nilai NMSE terkecil didapatkan pada batas antara 0.41 sampai dengan 0.6. Pada batas tersebut nilai rerata NMSE yang dihasilkan adalah sebesar 0.1587, hasil ini menunjukkan bahwa batas yang ideal untuk nilai parameter sigma agar dapat menghasilkan nilai peramalan terbaik yaitu pada batas antara 0.41 sampai dengan 0.6. Untuk lebih jelasnya grafik rerata nilai NMSE yang dihasilkan pada uji batas nilai parameter sigma dapat dilihat pada Gambar 14 berikut ini :



Gambar 14. Grafik Pengujian Batas Sigma

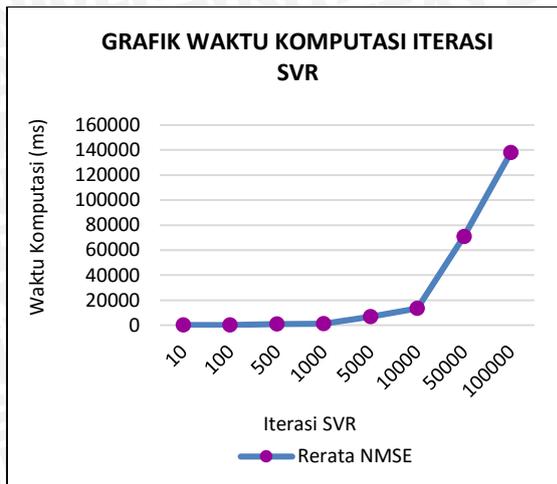
5.6 Analisis Pengujian Terhadap Jumlah Iterasi SVR

Pada uji coba kali ini dilakukan adalah uji coba jumlah iterasi SVR. Data yang digunakan dalam uji coba ini adalah harga BBM dari tahun 2001 – 2012 yang dibuat dalam data bulanan untuk meramalkan 31 bulan kedepannya. Untuk uji coba jumlah iterasi SVR ini digunakan iterasi maksimal ACO yaitu sebesar 150 dengan jumlah *Ant* sebanyak 7 serta dengan batas dimensi σ antara 0.6 sampai 0.7. Berdasarkan grafik hasil uji coba jumlah iterasi SVR pada Gambar 15, rerata nilai NMSE terkecil didapatkan dari jumlah iterasi 100000. Pada iterasi 100000 nilai rerata NMSE yang dihasilkan sebesar 0.108, hasil komputasi ini menunjukkan bahwa semakin banyak jumlah iterasi maka hasil NMSE yang didapatkan semakin baik. Oleh karena itu, berdasarkan analisa hasil uji coba pada Gambar 15 dapat disimpulkan bahwa jumlah iterasi paling optimal untuk metode SVR yaitu sejumlah 100000 kali iterasi.



Gambar 15. Grafik Pengujian Iterasi SVR

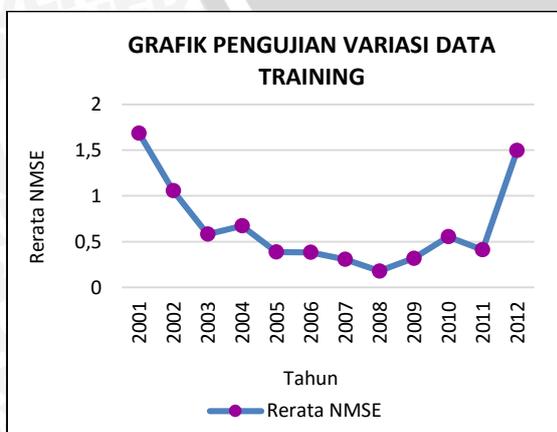
Selain dianalisa berdasarkan hasil rerata nilai NMSE setiap iterasi SVR, waktu komputasi juga menjadi salah satu acuan analisa dalam pengujian iterasi SVR. Berdasarkan Gambar 16 dapat dianalisa bahwa semakin banyak jumlah iterasi SVR, maka semakin lama waktu komputasinya.



Gambar 16. Grafik Waktu Komputasi Iterasi SVR

5.7 Analisis Pengujian Terhadap Variasi Data Training

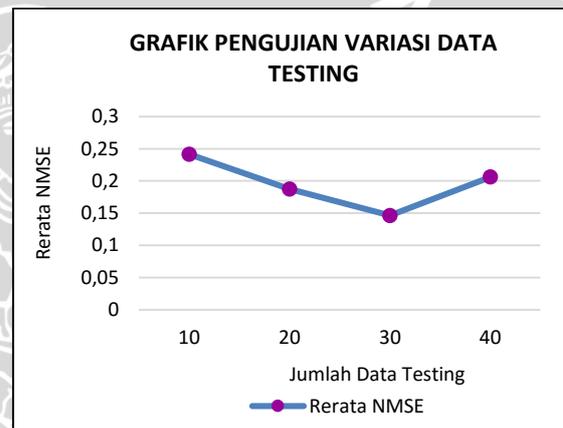
Pada uji coba variasi data *training* kali ini, data yang digunakan dalam uji coba adalah harga BBM dari tahun 2001 – 2012 yang dibuat dalam data bulanan. Berdasarkan grafik hasil uji coba variasi data *training* pada Gambar 17, rerata nilai NMSE terkecil didapatkan pada data harga BBM tahun 2008. Pada tahun 2008 nilai rerata NMSE yang dihasilkan adalah sebesar 0.1785, hasil ini menunjukkan bahwa data yang ideal untuk dijadikan data *training* agar dapat menghasilkan nilai peramalan terbaik yaitu data pada tahun 2008. Jika dianalisa lebih detail, variasi data *training* sangat berpengaruh terhadap hasil peramalan. Hal ini didukung dengan analisa terhadap variasi data harga BBM pada tahun 2008, data harga BBM pada tahun 2008 dapat menghasilkan rerata nilai NMSE lebih baik dikarenakan variasi data harga pada tahun tersebut lebih beragam dibandingkan dengan data harga BBM tahun-tahun lainnya. Untuk lebih jelasnya grafik rerata nilai NMSE yang dihasilkan pada uji variasi data *training* dapat dilihat pada Gambar 17 berikut ini :



Gambar 17. Grafik Pengujian Variasi Data Training

5.8 Analisis Pengujian Terhadap Variasi Data Testing

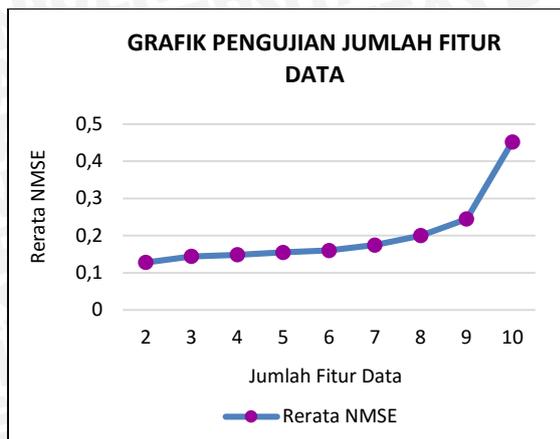
Berdasarkan analisa hasil uji coba variasi data *training*, didapatkan hasil bahwa data *training* terbaik yang dapat digunakan untuk peramalan yaitu data tahun 2001 sampai dengan tahun 2008. Oleh karena itu, untuk uji coba variasi data *testing* kali ini digunakan iterasi SVR sebesar 1000 dengan jumlah *Ant* sebanyak 7, dengan menggunakan data *training* dari tahun 2001 sampai dengan 2008. Berdasarkan grafik hasil uji coba variasi data *testing* pada Gambar 18, rerata nilai NMSE terkecil didapatkan dari 30 data *testing*. Pada jumlah 30 nilai rerata NMSE yang dihasilkan adalah sebesar 0.1462, hasil ini menunjukkan bahwa jumlah yang ideal data *testing* agar dapat menghasilkan nilai peramalan terbaik yaitu sejumlah 30 data. Untuk lebih jelasnya grafik rerata nilai NMSE yang dihasilkan pada uji variasi data *training* dapat dilihat pada Gambar 18 berikut ini:



Gambar 18. Grafik Pengujian Variasi Data Testing

5.9 Analisis Pengujian Terhadap Jumlah Fitur Data

Pengujian terakhir yaitu pengujian jumlah fitur data yang digunakan, pengujian ini dipengaruhi oleh hasil dari variasi data *training* dan variasi data *testing*. Data *training* yang digunakan pada pengujian jumlah fitur ini adalah data harga BBM tahun 2001 sampai dengan 2008, sedangkan data *testing* yang digunakan adalah sebanyak 30 data. Berdasarkan grafik hasil uji coba jumlah fitur data pada Gambar 19, rerata nilai NMSE terkecil didapatkan dengan jumlah fitur data sebanyak 2. Nilai rerata NMSE yang dihasilkan pada saat jumlah fitur data sebanyak 2 adalah sebesar 0.1276, hasil ini menunjukkan bahwa jumlah fitur data yang ideal agar dapat menghasilkan nilai peramalan terbaik yaitu sejumlah 2 fitur data. Untuk lebih jelasnya grafik rerata nilai NMSE yang dihasilkan pada uji coba jumlah fitur data dapat dilihat pada Gambar 19 berikut ini :



Gambar 19. Grafik Pengujian Jumlah Fitur Data

6. PENUTUP

6.1 Kesimpulan

Koefisien yang dihasilkan pada penelitian ini menghasilkan nilai *error* yang cukup rendah. Nilai NMSE yang dihasilkan dengan menggunakan metode SVR-ACO ini yaitu sebesar 0.108%. Berdasarkan perolehan hasil nilai NMSE tersebut dapat disimpulkan bahwa Algoritma *Ant Colony Optimization* (ACO) dapat diimplementasikan untuk optimasi peramalan harga BBM menggunakan metode *Support Vector Regression* (SVR) dengan menemukan koefisien-koefisien terbaik untuk setiap parameter SVR yang dioptimasi. Dalam penelitian ini terdapat tiga parameter metode SVR yang dioptimasi menggunakan ACO diantaranya yaitu nilai kompleksitas, nilai epsilon dan nilai sigma. Adapun batas rentang nilai yang dibangkitkan ACO untuk setiap parameter tersebut berbeda-beda, batas rentang untuk nilai kompleksitas yaitu antara [101, 1000], batas rentang untuk nilai epsilon yaitu antara [0.0001, 0.1] dan batas rentang untuk nilai sigma yaitu antara [0.41, 0.6]. Panjang data yang digunakan dalam SVR adalah sebanyak 99 data yang berisi data harga BBM dalam rentang waktu perbulan, dengan panjang fitur data sebanyak 5 fitur.

6.2 Saran

1. Algoritma *Ant Colony Optimization* (ACO) merupakan algoritma yang bersifat *stochastic* sehingga rentang nilai yang dihasilkan juga cukup luas. Hal ini menjadi salah satu permasalahan dalam menganalisa hasil peramalan, dikarenakan nilai peramalan yang dihasilkan menjadi sangat acak. Oleh karena itu pada penelitian selanjutnya, perlu diperhatikan untuk menambahkan batas rentang pembangkitan nilai yang tepat agar dapat menghasilkan nilai peramalan yang optimal. Salah satu cara untuk menentukan batas nilai yang tepat untuk setiap parameter

yaitu dengan cara melakukan uji coba batas rentang nilai untuk setiap parameter.

2. Semakin banyak jumlah data *training* yang digunakan, peramalan harga BBM yang dihasilkan juga semakin baik. Pada penelitian ini peneliti hanya menggunakan data harga BBM 12 tahun terakhir yaitu data harga BBM tahun 2001 sampai tahun 2012, oleh karena itu untuk menghasilkan nilai peramalan yang lebih baik maka bisa dilakukan dengan cara menambah jumlah data harga BBM dari tahun 2013 sampai tahun 2015.
3. Pada penelitian berikutnya peneliti bisa mencoba mengoptimasi nilai parameter SVR yang lain, selain parameter yang sudah dioptimasi pada penelitian yang telah dilakukan saat ini. Hal ini bertujuan untuk memperoleh nilai koefisien yang optimal untuk setiap parameter SVR, sehingga dapat menghasilkan nilai peramalan yang lebih baik.
4. Dalam penelitian selanjutnya dapat dipertimbangkan untuk mengkaji ulang mengenai patokan rumus perhitungan harga BBM yang digunakan oleh pemerintah selama ini, serta mengkaji ulang mengenai kebijakan pemerintah atas kenaikan dan penurunan harga BBM yang terjadi setiap tahunnya.

DAFTAR PUSTAKA

- [BAO-11] Bao, Y., 2011. A Comparative Study of Multi-step-ahead Prediction for Crude Oil Price with *Support Vector Regression*, [e-journal] pp.598 – 602. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015]
- [CAR-11] Carwoto, 2011. Rancangan Otomasi Berbasis Internet Untuk Pengendalian Proses Penyaluran Bahan Bakar Minyak (BBM) Bersubsidi, [e-journal] pp.E.25 - E30. Tersedia melalui: IPI Indonesian Publication Index <<http://portalgaruda.org>> [Diakses 11 September 2015].
- [HON-10] Hong, W.C., 2010. Electric Load Forecasting by SVR with Chaotic Ant Swarm Optimization, [e-journal] pp.102 – 107. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [KUN-12] Kun, L., 2012. Rice Blast Prediction Based on Gray Ant Colony And RBF Neural Network Combination Model, [e-journal] pp.144 – 147. Tersedia

- melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [KUO-14] Kuo, B.C., 2014. A Kernel-Based Feature Selection Method for SVM With RBF Kernel for Hyperspectral Image Classification, [e-journal] pp.317 – 326. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [LI-13] Li, X., 2013. Coupling Firefly Algorithm and Least Squares Support Vector Regression for Crude Oil Price Forecasting, [e-journal] pp.80 – 83. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [LIX-10] Lixing, D., 2010. Support Vector Regression and Ant Colony Optimization for HVAC Cooling Load Prediction, [e-journal] pp.537 – 541. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [MAR-12] Martin, A., 2012. An Analysis on Qualitative Bankruptcy Prediction Using Fuzzy ID3 and Ant Colony Optimization Algorithm, [e-journal]. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [MEE-13] Meesad, P., 2013. Predicting Stock Market Price Using Support Vector Regression, [e-journal] pp.416 – 421. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [MOH-14] Mohanthy, R., 2014. Predicting Software Reliability Using Ant Colony Optimization, [e-journal] pp.496 – 500. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [NAH-13] Nahumury, M.A.I., 2013. Analisis Faktor-Faktor Yang Mempengaruhi Pendapatan Pedagang Bahan Bakar Minyak (BBM) Bensin Eceran Di Kabupaten Merauke, [e-journal] pp.441 - 450. Tersedia melalui: IPI Indonesian Publication Index <<http://portalgaruda.org>> [Diakses 11 September 2015].
- [PAR-14] Parmadi, N.K.A.R., 2014. Analisis Reaksi Investor Terhadap Kenaikan Harga Bahan Bakar Minyak Di Bursa Efek Indonesia, [e-journal]. Tersedia melalui: IPI Indonesian Publication Index <<http://portalgaruda.org>> [Diakses 11 September 2015].
- [PIN-11] Ping, Y., 2011. On-line Adaptation Algorithm for RBF Kernel Based FS-SVM, [e-journal] pp.3963 – 3967. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [RAJ-13] Rajkumar, N., 2013. A new RBF kernel based learning method applied to multiclass dermatology diseases classification, [e-journal] pp.551 – 556. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [SEP-15] Septiningrum, L., 2015. Prediksi Indeks Harga Saham Gabungan Menggunakan Support Vector Regression (SVR) Dengan Algoritma Grid Search, [e-journal] pp.315 – 321. Tersedia melalui : IPI Indonesian Publication Index <<http://portalgaruda.org>> [Diakses 11 September 2015].
- [SUN-10] Sun, C., 2010. Gas Bearing Capacity Forecasting Method Based on Ant Colony Optimization and Support Vector Regression, [e-journal] pp.387 – 390. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [SUP-14] Suparsa, I.M.J., 2014. Perbedaan Abnormal Return Dan Trading Volume Activity Atas Pengumuman Kenaikan Harga BBM Pada Saham Yang Tergolong Lq 45, [e-journal] pp.382 – 390. Tersedia melalui : IPI Indonesian Publication Index <<http://portalgaruda.org>> [Diakses 11 September 2015].
- [TIA-14] Tianshi, L., 2014. Improved Ant Colony Optimization for Interval Pumping of Pumping Unit, [e-journal] pp.550 – 555. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [TYA-13] Tyas, Y.S., 2013. Aplikasi Pencarian Rute Terbaik dengan Metode Ant Colony Optimazation (ACO), [e-journal] pp.55 – 64. Tersedia melalui : IPI Indonesian Publication Index <<http://portalgaruda.org>>

- [VIJ-99] [Diakses 11 September 2015].
Vijayakumar, S., 1999. Sequential Support Vector Classifiers and Regression. In Proceedings of International Conference on Soft Computing (SOCO '99). pp. 610–619.
- [WAL-09] Waliprana, W.E., 2009. *Ant Colony Optimization*, [e-journal]. Tersedia melalui : IPI Indonesian Publication Index <<http://http://portalgaruda.org>> [Diakses 12 September 2015].
- [WAN-13] Wang, H., 2013. Electricity Consumption Prediction Based on SVR with *Ant Colony Optimization*, [e-journal] pp. 6928-6934 . Tersedia melalui : IPI Indonesian Publication Index <http://portalgaruda.org> [Diakses 11 September 2015].
- [XIN-13] Xing, H., 2013. An New Strategy for Online Evaluation of Analog Circuit Performance based Adaptive Least Squares *Support Vector Regression* with Double Kernel RBF, [e-journal] pp.120 – 124. Tersedia melalui: IEEE Xplore Digital Library <<http://ieeexplore.ieee.org>> [Diakses 11 September 2015].
- [YAN-14] Yasin, H., 2014. Prediksi Harga Saham Menggunakan *Support Vector Regression* Dengan Algoritma Grid Search, [e-journal] pp. 29 - 35. Tersedia melalui : IPI Indonesian Publication Index <http://portalgaruda.org> [Diakses 12 September 2015].

