

Peramalan Harga Batubara Acuan Menggunakan Metode PSOSVR dan IPSOSVR

Alliseu Umiyati*, Dadan Dasari, dan Fitriani Agustina

Program Studi Matematika

Fakultas Pendidikan Matematika dan Ilmu Pengetahuan Alam

Universitas Pendidikan Indonesia

Email: alliseumiyati@yahoo.com

ABSTRAK. Batubara adalah salah satu jenis bahan bakar fosil yang sering dimanfaatkan oleh perusahaan industri. Sebuah model prediksi harga batubara acuan untuk melihat harga batubara acuan di masa yang akan datang sangat diperlukan, sehingga perusahaan industri dapat mengalokasikan dana dengan tepat untuk memaksimalkan keuntungan dan meminimumkan biaya produksi. Terdapat beberapa studi yang membahas tentang prediksi harga batubara acuan menggunakan *machine learning* yang salah satunya yaitu menggunakan *support vector regression* (SVR). Namun, metode tersebut masih memiliki kekurangan pada penentuan nilai parameter yang tepat. Dalam proses penentuan nilai parameter yang tepat tersebut diperlukan bantuan algoritma optimasi. Oleh karena itu, penelitian ini bertujuan untuk melakukan peramalan harga batubara acuan menggunakan data historis periode bulan Januari 2009 sampai dengan bulan Oktober 2019, dengan menggunakan metode *support vector regression* (SVR) yang dioptimasi dengan *particle swarm optimization* (PSO) dan *improved-particle swarm optimization* (IPSO). Hasil peramalan kemudian dievaluasi menggunakan MAPE. Berdasarkan penelitian yang telah dilakukan, prediksi harga batubara acuan menggunakan metode PSOSVR menghasilkan nilai MAPE sebesar 3,911% dan metode IPSOSVR menghasilkan nilai MAPE sebesar 3,916%. Sedangkan untuk prediksi menggunakan parameter SVR yang tidak dioptimasi menghasilkan nilai MAPE sebesar 13,388%.

Kata Kunci : Peramalan, Harga Batubara Acuan, *Support Vector Regression*, *Particle Swarm Optimization*, *Improved-Particle Swarm Optimization*, *Mean Absolute Percentage Error*.

Forecasting Coal Price Index using PSOSVR and IPSOSVR Methods

ABSTRACT. Coal is a type of fossil fuel that is often used by industrial companies. A prediction model of coal prices index to see future coal prices is needed, so that industrial companies can allocate funds appropriately to maximize profits and minimize production costs. There are several studies that discuss the prediction of reference coal prices using machine learning, one of which is using support vector regression (SVR). However, this method still has shortcomings in determining the correct parameter values. An optimization algorithm is needed to help determine the right parameter value. Therefore, this study aims to forecast reference coal prices using historical data for the period January 2009 to October 2019, using the support vector regression (SVR) method that is optimized with particle swarm optimization (PSO) and improved-particle swarm optimization (IPSO), which is evaluated using the MAPE forecasting results. Based on research that has been done, the prediction of reference coal prices using the PSOSVR method produces a MAPE value of 3.911% and the IPSOSVR method produces a MAPE value of 3.916%. Whereas the prediction using SVR parameters that is not optimized produces a MAPE value of 13.388%.

Keywords : Forecasting, Coal Price Index, Support Vector Regression, Particle Swarm Optimization, Improved-Particle Swarm Optimization, Mean Absolute Percentage Error.

1. PENDAHULUAN

Batubara adalah salah satu bahan bakar fosil. Batubara dapat terbakar yang terbentuk dari endapan batuan organik yang terutama terdiri dari karbon, hidrogen dan oksigen. Beberapa manfaat batubara yaitu sebagai bahan baku pembangkit listrik tenaga uap (PLTU), campuran pada industri semen, campuran pada proses peleburan besi dan baja, bahan baku pada industri kimia, dan masih banyak manfaat lainnya.

Seperti telah dikemukakan di atas bahwa batubara banyak dimanfaatkan untuk bidang industri. Perusahaan bidang industri memperoleh batubara yang diperlukan pada proses produksinya, dengan cara membeli dari perusahaan pertambangan batubara. Dengan demikian, perusahaan bidang industri yang memanfaatkan batubara, perlu mengalokasikan anggaran dana untuk memenuhi kebutuhan batubara. Faktor utama dalam penyusunan anggaran dana yaitu nilai perkiraan harga-harga kebutuhan perusahaan, salah satunya perkiraan harga batubara.

Harga batubara acuan atau HBA adalah harga yang diperoleh dari rata-rata indeks *Indonesia Coal Index* (ICI), *Newcastle Export Index* (NEX), *Globalcoal Newcastle Index* (GCNC), dan Platt's 5900 pada bulan sebelumnya (Ditjen Minerba Kemetrian ESDM, 2019). Harga batubara acuan merupakan data *time series*, sehingga harga batubara dapat diramalkan menggunakan analisis data *time series*.

Salah satu teknik peramalan yang paling sederhana adalah analisis regresi. Berdasarkan kelinierannya analisis regresi dibagi menjadi dua yaitu analisis regresiliner dan analisis regresi non linear. Analisis regresi yang sering digunakan adalah analisis regresi linear, namun pada kenyataannya, banyak data yang tidak memenuhi asumsi kelinearan sehingga regresi linear tidak digunakan. Apabila asumsi kelinieran tidak terpenuhi maka dapat diselesaikan dengan metode *Support Vector Machine* (SVM).

Support Vector Machine (SVM) adalah salah satu metode yang digunakan untuk mengatasi data non linear. SVM yang digunakan untuk kasus regresi dinamakan *Support Vector Regression* (SVR). Namun *Support Vector Regression* (SVR) susah untuk menentukan parameter yang optimal, maka dari itu diperlukan penggabungan metode SVR dengan metode lain untuk mengoptimasi parameter.

Particle Swarm Optimization (PSO) adalah salah satu alat untuk memilih fitur mana saja yang berpengaruh terhadap model prediksi. PSO juga dikenal sebagai alat untuk mencari karakteristik optimum atau masalah optimum dengan

bantuan optimum local dan optimum global di ruang fitur secara iteratif.

Selanjutnya indikator atau fitur yang terpilih akan dijadikan data input pada prediksi dengan menggunakan *Support Vector Regression* (SVR). SVR merupakan salah satu metode *supervised learning* untuk menemukan sebuah fungsi (x) sebagai *hyperplane* berupa fungsi regresi, dimana fungsi ini harus memiliki error yang kecil ϵ atau tidak melebihi ϵ dari nilai target aktual y_i untuk semua data *training*.

Pada penelitian ini penulis akan membandingkan penggunaan metode *Support Vector Regression* (SVR) yang dioptimasi dengan algoritma *Particle Swarm Optimization* (PSO) dan metode *Support Vector Regression* (SVR) yang dioptimasi dengan algoritma *Improved-Particle Swarm Optimization* (IPSO) dalam memprediksi harga batubara.

2. METODE

2.1 Particle Sawrm Optimization (PSO)

Particle swarm optimization (PSO) pertama kali dikenalkan oleh Dr. Kennedy dan Dr. Eberhart pada tahun 1995. PSO merupakan Teknik *metaheuristic* yang meniru perilaku sosial kawanan burung dan sekelompok ikan dengan tiap individunya dimisalkan dengan partikel (Kennedy & Eberhart, 1995). Perilaku sosial yang dimaksud yaitu terdiri dari perilaku tiap individu itu sendiri serta pengaruh perilaku individu lain yang terdapat dalam suatu kelompok (Kennedy & Eberhart, 1995). Pergerakan tiap partikel di ruang solusi dipengaruhi oleh kecepatan masing – masing partikel, posisi terbaik yang diperoleh oleh partikel itu sendiri (*pbest*) dan posisi terbaik yang diperoleh dari kelompok partikel (*gbest*). Berikut adalah rumus untuk memperbarui kecepatan dan posisi tiap partikel (Qasim & Algamal, 2018) (Qasim & Algamal, 2018):

$$V_i(t+1) = w \times V_i(t) + c_1 \times r_1 \times [pbest_i(t) - X_i(t)] + c_2 \times r_2 \times [gbest(t) - X_i(t)] \quad (1)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (2)$$

dimana $V_i(t)$ merupakan kecepatan partikel i pada iterasi ke t , $X_i(t)$ merupakan posisi partikel i pada iterasi ke t . $pbest_i(t)$ merupakan posisi terbaik yang diperoleh oleh partikel i pada iterasi sejauh t , $gbest(t)$ merupakan posisi terbaik dari sekelompok partikel pada iterasi sejauh t , w merupakan bobot inersia yang nilainya terletak di $[0,1]$, c_1 dan c_2 merupakan koefisien akselerasi yang nilainya terletak di $[0,4]$, r_1 dan r_2 merupakan bilangan acak yang nilainya terletak di $[0,1]$.

2.2 Support Vector Regression (SVR)

Support Vector Machine (SVM) pertama kali ditemukan oleh Vlandimir Vapnik dan rekannya pada tahun 1995. SVM merupakan salah satu *Machine learning* yang termasuk dalam metode *Supervised Learning* digunakan untuk menyelesaikan masalah klasifikasi (Vapnik, 1999). SVM dikembangkan untuk menyelesaikan kasus regresi yang disebut *Support Vector Regression* (SVR). Ide utama dari SVR yaitu mencari sebuah fungsi $y(x)$ sebagai *hyperplane* berupa fungsi regresi yang akan memaksimalkan margin (Smola & Scholkopf, 2004).

2.3 Optimasi PSOSVR

Proses optimasi PSOSVR merupakan proses optimasi menggunakan algoritma PSO dengan SVR sebagai evaluasi fungsi *fitnessnya*, proses optimasi dilakukan dengan tujuan untuk mengetahui nilai parameter yang paling optimal. Data yang digunakan dalam proses optimasi PSOSVR ini merupakan data yang telah melalui proses normalisasi. Parameter yang akan dioptimasi adalah parameter C , ε , σ , cLR , dan λ . Berikut penjelasan mengenai proses optimasi PSOSVR :

Langkah 1 Menghitung K-Fold Cross Validation. K-Fold Cross Validation merupakan proses mempersiapkan data yang akan digunakan untuk melatih SVR (Hastie et al., 2009). K-Fold Cross Validation dilakukan dengan tujuan untuk mengestimasi tingkat kesalahan. K-Fold Cross Validation dilakukan dengan cara mengelompokkan antara data latih dan data uji dari keseluruhan data. Proses pengelompokkan data latih dan data uji dilakukan dengan tahapan sebagai berikut: (1) mengacak urutan hasil normalisasi data, (2) mencari indeks awal dan akhir data uji, dan (3) mendefinisikan data latih dan data uji sebanyak K kali.

Langkah 2 Inisialisasi Partikel

1. Inisialisasi Posisi Partikel

Pada proses inisialisasi posisi partikel diasumsikan bahwa sebuah partikel untuk setiap dimensinya harus berada dalam domain yang didefinisikan oleh dua vektor, yaitu x_{min} dan x_{max} . x_{min} mewakili batas bawah setiap dimensi dan x_{max} mewakili batas atas setiap dimensi. Berdasarkan Engelbrecht A. P. (Engelbrecht, 2007), metode inisialisasi untuk posisi partikel adalah:

$$\begin{aligned} x(0) &= x_{min,j} + r_j(x_{max,j} - x_{min,j}) \\ \forall j &= 1, \dots, n_x \quad \forall i = 1, \dots, n_s \end{aligned} \quad (3)$$

dimana x merupakan posisi partikel (merepresentasikan nilai C , ε , σ , cLR , λ) dan r_j merupakan nilai acak dalam range $[0,1]$.

2. Inisialisasi Kecepatan Partikel

Pada proses kecepatan awal partikel diinisialisasikan menjadi nol $v_i(0) = 0$. Dalam implementasi PSO, terkadang ditemukan bahwa kecepatan partikel bergerak ke nilai yang besar dengan cepat. Akibatnya, partikel tersebut memiliki kecenderungan untuk keluar dari ruang batas pencarian. Oleh karena itu, perlu adanya pembatasan kecepatan minimum dan maksimum untuk mencegah partikel bergerak terlalu jauh melampaui ruang pencarian. Berdasarkan Marini & Walczak (2015), inisialisasi pembatasan kecepatan ditentukan dengan menggunakan persamaan berikut:

$$v_{max,j} = k \frac{x_{max,j} - x_{min,j}}{2} \quad (4)$$

dimana $v_{max,j}$ merupakan kecepatan maksimum dimensi j, k merupakan nilai acak dari 0-1, $x_{max,j}$ mewakili batas atas dimensi j dan $x_{min,j}$ mewakili batas bawah dimensi j.

Batasan kecepatan yang digunakan adalah sebagai berikut: Jika $V_i(t) > v_{max,j}$ maka $V_i(t) = v_{max,j}$ (Marini & Walczak, 2015).

Langkah 3 Mengevaluasi Fungsi *Fitness*. Evaluasi fungsi *fitness* dilakukan dengan pelatihan SVR. Tahapan yang dilakukan pada evaluasi fungsi *fitness* adalah

(1) memilih fitur yang akan digunakan berdasarkan fitur yang dipilih, (2) melakukan *sequential learning*, (3) menguji model regresi dengan data uji dan (4) menghitung nilai error dan nilai cost.

Langkah 4 Mencari nilai *pBest*. *pBest* merupakan posisi terbaik yang pernah dicapai partikel. Proses pencarian nilai *pBest* dilakukan dengan cara membandingkan nilai cost *pBest* dengan partikel iterasi saat ini. Apabila nilai cost *pBest* lebih kecil dari nilai cost partikel iterasi saat ini, maka nilai posisi *pBest* tetap. Namun, apabila nilai cost *pBest* lebih besar dari nilai cost partikel iterasi saat ini, maka nilai posisi *pBest* akan digantikan oleh nilai posisi partikel saat ini..

Langkah 5 Mencari Nilai *gBest* dan Nilai Bobot Inersia Baru. *gBest* merupakan posisi terbaik partikel. Proses pencarian nilai *gBest* dilakukan dengan cara membandingkan nilai cost *gBest* dan *pBest*. Apabila nilai cost *gBest* lebih kecil dari nilai cost *pBest*, maka nilai posisi *gBest* tetap. Namun, apabila nilai cost *gBest* lebih besar dari nilai cost *pBest*, maka nilai posisi *gBest* digantikan oleh nilai posisi *pBest*. Menghitung nilai bobot inersia baru ditentukan dengan menggunakan perumusan sebagai berikut (Zhang et al., 2016):

$$w = w_{max} - \frac{w_{max} - w_{min}}{t_{max}} \times t \quad (5)$$

dimana w merupakan bobot inersia, w_{max} merupakan batas atas bobot inersia, w_{min} merupakan batas bawah bobot inersia, t_{max} merupakan iterasi maksimal dan t merupakan iterasi saat ini.

Langkah 6 Memperbarui Kecepatan Partikel. Proses memperbarui kecepatan partikel dilakukan dengan menggunakan persamaan (1).

Langkah 7 Memperbarui Posisi Partikel. Proses memperbarui posisi partikel dilakukan dengan menggunakan persamaan (2).

Langkah 8 Mengulangi langkah 1-7 sampai diperoleh kondisi yang konvergen yaitu kondisi pada saat maksimal iterasi.

Langkah 9 Menentukan hasil optimal parameter SVR dan jumlah fitur pilihan dari nilai $gBest$.

2.4 Optimasi PSOSVR

Proses optimasi IPSOSVR merupakan proses optimasi menggunakan algoritma IPSO dengan SVR sebagai evaluasi fungsi *fitness*nya, proses optimasi dilakukan dengan tujuan untuk mengetahui nilai parameter yang paling optimal. Data yang digunakan dalam proses optimasi IPSOSVR ini merupakan data yang telah melalui proses normalisasi. Parameter yang akan dioptimasi adalah parameter C , ε , σ , cLR , dan λ . Proses optimasi PSOSVR sama seperti proses optimasi PSOSVR, namun untuk memperbarui kecepatan partikel Zou et al. (2015) menambahkan λ sebagai faktor konvergen yang diletakkan di depan bobot inersia, dimana $\lambda = \sin^3 \alpha$ dan $\alpha = [0, \pi/8]$. Proses memperbarui kecepatan partikel dilakukan dengan menggunakan persamaan:

$$V_i(t+1) = \lambda \times w \times V_i(t) + c_1 \times r_1 \times [pbest_i(t) - X_i(t)] + c_2 \times r_2 \times [gbest(t) - X_i(t)] \quad (6)$$

Proses memperbarui posisi partikel dilakukan dengan menggunakan persamaan berikut (Zou et al., 2015):

$$X_i(t+1) = X_i(t) + \lambda \times w \times V_i(t+1) \quad (7)$$

2.5 Prediksi SVR

Dalam tahap ini nilai parameter optimal yang telah diperoleh pada tahap optimasi sebelumnya akan digunakan untuk memprediksi harga batubara acuan menggunakan metode SVR. Langkah-langkah prediksi sebagai berikut :

Langkah 1 Memilih fitur masukan. Fitur masukan disini berdasarkan hasil dari optimasi PSOSVR dan IPSOSVR

Langkah 2 Penentuan data latih dan data uji

Langkah 3 *Sequential Learning*. Adapun langkah-langkahnya adalah sebagai berikut (Khair et al., 2017):

1. Inisialisasi parameter SVR yang digunakan dan inisialisasi nilai awal a_i dan a^*

i sebesar 0.

2. Menentukan matriks Hessian dengan persamaan

$$[R_{ij}] = \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) + \lambda^2 \quad (8)$$

Keluaran dari matriks Hessian kemudian dimasukkan pada persamaan dibawah untuk mencari nilai γ yang berfungsi mengontrol kecepatan proses *learning* dimana *cLR* adalah kontanta *learning rate*

$$\gamma = \frac{cLR}{\max(R_{ij})} \quad (9)$$

3. Untuk setiap data latih, hitung nilai error dengan persamaan berikut

$$E_i = y_i - \sum (\mathbf{a}_i - \mathbf{a}^*)_i R_{ij} \quad (10)$$

Hitung perubahan nilai *Lagrange multiplier* dengan persamaan berikut

$$\star \mathbf{a}^*_i = \min\{\max(y(E_i - \varepsilon), -\mathbf{a}^*)_i, C - \mathbf{a}^*)_i\} \quad (11)$$

$$\star \mathbf{a}_i = \min\{\max(y(-E_i - \varepsilon), -\mathbf{a}_i), C - \mathbf{a}_i)\} \quad (12)$$

Hitung nilai *Lagrange multiplier* yang baru dengan persamaan berikut

$$\mathbf{a}^*_i(\text{baru}) = \delta \mathbf{a}^*_i + \mathbf{a}^*_i \quad (13)$$

$$\mathbf{a}_i(\text{baru}) = \delta \mathbf{a}_i + \mathbf{a}_i \quad (14)$$

dimana y_i adalah nilai aktual ke- i , ε adalah *epsilon*, dan C adalah nilai kompleksitas

4. Ulangi langkah 3 sampai iterasi maksimum yang ditentukan atau telah mencapai konvergensi dengan syarat $\max(|\delta \mathbf{a}^*|) < \varepsilon$ dan $\max(|\delta \mathbf{a}_i|) < \varepsilon$.
5. Menguji model regresi yaitu proses memperoleh hasil regresi dari model regresi yang telah dibangun. Proses ini dimulai dengan menghitung fungsi regresi untuk memberikan hasil prediksi dengan perkalian antara nilai *Lagrange multiplier* terakhir yang dihasilkan dan matrik Hessian, dengan persamaan (Khair et al., 2017):

$$\mathbf{f}(\mathbf{x}) = \sum_{i=1}^n (\mathbf{a}^*_i - \mathbf{a})(\mathbf{K}(\mathbf{x}, \mathbf{x}_i) + \lambda^2) \quad (15)$$

Langkah selanjutnya adalah denormalisasi untuk mengembalikan data sehingga didapatkan *predicted value* menggunakan persamaan berikut (Smola & Scholkopf, 2004):

$$\mathbf{x}_i = \mathbf{f}(\mathbf{x}_i)(\mathbf{x}_{max} - \mathbf{x}_{min}) + \mathbf{x}_{min} \quad (16)$$

dimana x_i merupakan nilai data normal, $f(x_i)$ merupakan hasil output ke- i , x_{max} merupakan data dengan nilai maksimum dan x_{min} merupakan data dengan nilai minimum.

6. Menentukan nilai error yaitu proses menghitung tingkat akurasi hasil regresi. Proses ini dimulai dengan menghitung nilai *mean absolute percentage error* (MAPE) dengan menggunakan persamaan sebagai

berikut (Khair et al., 2017):

$$MAPE = \frac{1}{n} \sum_{i=1}^n |PE| * 100\%$$

$$|PE| = \left| \frac{A_i - F_i}{A_i} \right| \quad (17)$$

dimana n merupakan banyak data, A_i merupakan nilai aktual dan F_i merupakan nilai prediksi pada data ke- i

Hasil MAPE yang didapat selanjutnya dikategorikan ke dalam beberapa kriteria yang mengindikasikan hasil tersebut (Khair, 2017).

Tabel 2. 1 Kriteria Nilai MAPE

Nilai MAPE	Kriteria
<10%	Sangat Baik
10% - 20%	Baik
20% - 50%	Cukup
>50%	Buruk

3. HASIL PENELITIAN DAN PEMBAHASAN

Bagian ini membahas mengenai studi kasus pada peramalan harga batubara acuan, data yang digunakan diperoleh dari *website* resmi Kementerian Energi Dan Sumber Daya Mineral. Data tersebut adalah data harga batubara acuan per bulan dengan rentang data yang diambil yaitu mulai dari bulan Januari 2009 sampai Oktober 2019 sebanyak 130 data.

3.1 Pengujian Menggunakan Metode PSOSVR

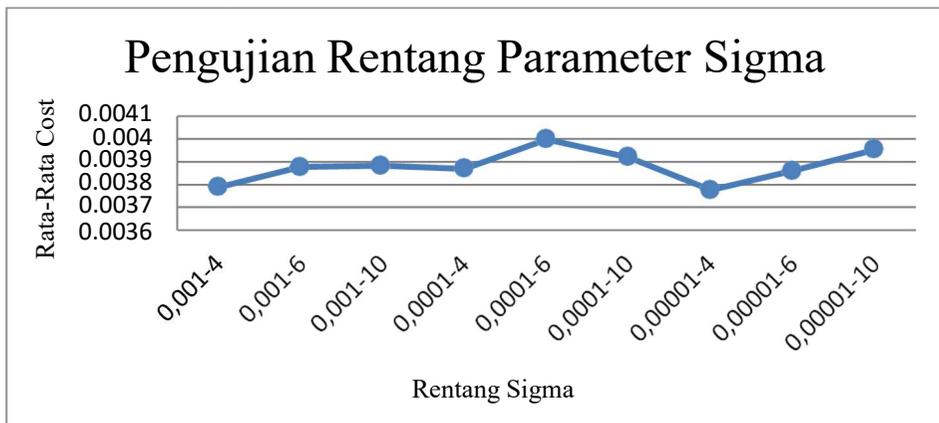
3.3.1 Pengujian Rentang Parameter

Pengujian rentang parameter ini dilakukan untuk memperoleh rentang parameter yang optimal dari parameter λ (*lamda*), ε (*epsilon*), cLR (*learning rate*), C (kompleksitas), dan σ (*sigma*). Selain itu pengujian rentang parameter dilakukan dengan tujuan untuk mendapatkan hasil pengujian nilai parameter terbaik yang akan digunakan dalam optimasi parameter dengan metode PSOSVR dan prediksi harga batubara acuan. Nilai rentang parameter tersebut akan berpengaruh terhadap besar nilai parameternya. Untuk setiap pengujian diulang sebanyak 10 kali. Pengujian pertama dilakukan dengan menggunakan rentang parameter awal yang diperoleh berdasarkan hasil-hasil penelitian sebelumnya, yaitu sebagai berikut :

- Rentang parameter C : 0,01 – 1000 (Vijayakumar, 1999)
- Rentang parameter ε : 0,00001 – 0,1 (Chai, 2011)

- Rentang parameter cLR : 0,01 – 2 (Vijayakumar, 1999)
- Rentang parameter λ : 1 - 67 (Cholissodin & Riyandani, 2016)
- Jumlah partikel : 20 (Hseih et al., 2011)
- Jumlah iterasi : 10 (Novitasari et al., 2016)
- Nilai $C1$ dan $C2$: 1&1 (Novitasari et al., 2016)
- Nilai $wMax$ dan $wMin$: 0,9 dan 0,4 (Cholissodin, 2016)
- Nilai K : 10 (Saputro, 2017)

1. Parameter Sigma

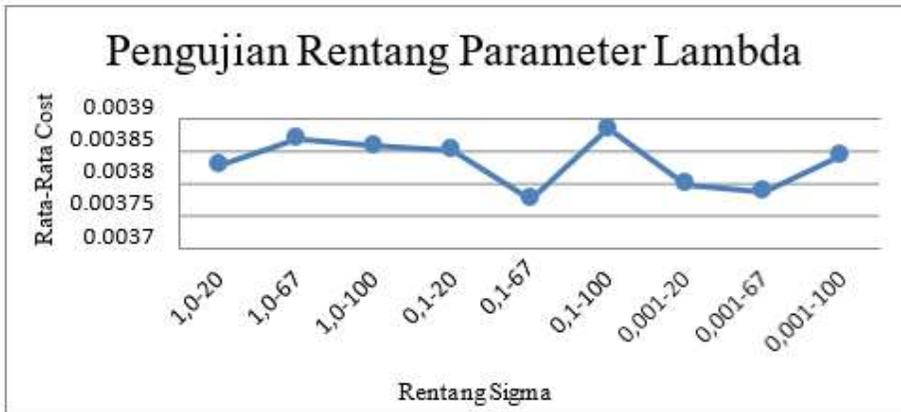


Gambar 3. 1 Grafik Penguujian Rentang Parameter σ Metode PSOSVR

Berdasarkan Gambar 3.1, dapat diperoleh informasi bahwa nilai rata-rata *cost* cenderung naik mengikuti batas atas yang semakin membesar. Pada penguujian ini rentang parameter σ yang paling optimal adalah pada rentang 0,00001-4.

2. Parameter Lambda

Rentang parameter σ yang digunakan berdasarkan hasil penguujian parameter σ sebelumnya pada point 1. Sedangkan rincian parameter lain yang akan digunakan berdasarkan penguujian awal.

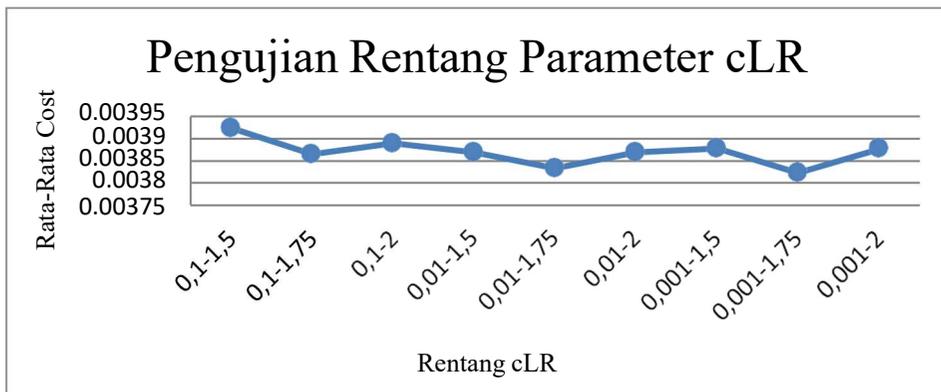


Gambar 3. 2 Grafik Pengujian Rentang Parameter λ Metode PSOSVR

Berdasarkan Gambar 3.2. Diketahui bahwa nilai rata-rata *cost* terendah diperoleh pada rentang 0,1-67. Pada umumnya, semakin besar rentang parameter λ semakin baik keakuratan regresinya. Tetapi, jika terlalu besar rentang parameter λ akan memberikan efek yaitu mengakibatkan rendahnya kecepatan konvergensi yang akan membutuhkan komputasi yang lebih lama dan membuat proses tidak stabil (Vijayakumar, 1999).

3. Parameter cLR

Rentang parameter σ dan λ yang digunakan berdasarkan hasil pengujian parameter σ dan λ sebelumnya pada point 1 dan 2. Sedangkan rincian parameter lain yang akan digunakan berdasarkan pengujian awal.

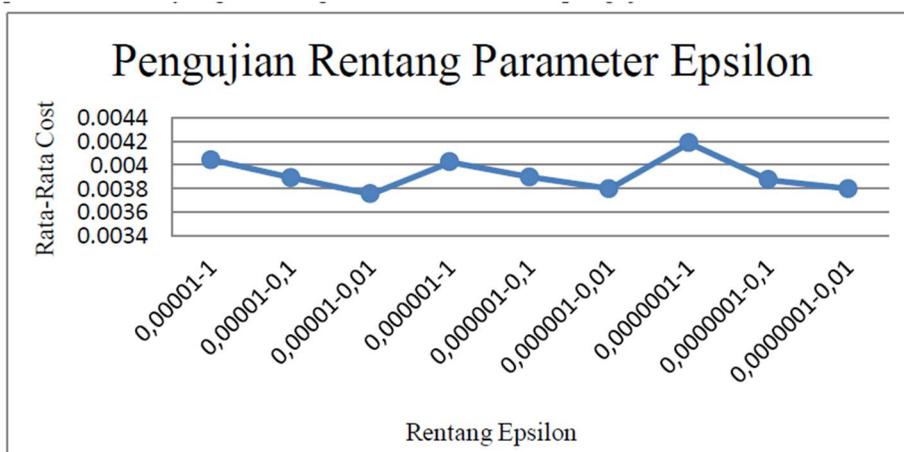


Gambar 3.3 Grafik Pengujian Rentang Parameter cLR Metode PSOSVR

Berdasarkan Gambar 3.3 diperoleh informasi bahwa, rata-rata nilai *cost* terkecil diperoleh pada rentang parameter 0,001-1,75. Parameter cLR yang berada pada rentang tersebut dapat menghasilkan *learning rate* (γ) yang mampu membangun model dengan tingkat akurasi yang tinggi. Semakin kecil nilai *learning rate* (γ), maka proses *learning* akan lebih lama namun mendapatkan hasil konvergen (Vijayakumar, 1999).

4. Parameter Epsilon

Rentang parameter σ , λ dan cLR yang digunakan berdasarkan hasil pengujian parameter σ , λ dan cLR sebelumnya pada point 1, 2 dan 3. Sedangkan rincian parameter lain yang akan digunakan berdasarkan pengujian awal.

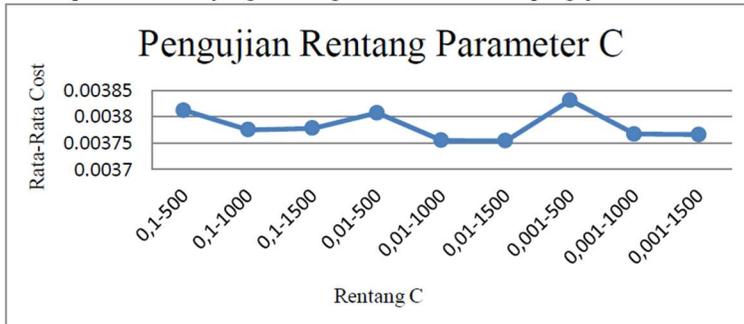


Gambar 3.4 Grafik Pengujian Rentang Parameter ϵ Metode PSOSVR

Berdasarkan Gambar 3.4 diperoleh informasi bahwa semakin kecil batas bawah maka nilai rata-rata *cost* yang dihasilkan pun semakin kecil. Nilai parameter ϵ mempengaruhi jumlah *support vector* yang digunakan untuk membangun fungsi regresi. Semakin besar nilai parameter ϵ yang dipilih, maka semakin sedikit jumlah *support vector* yang terpilih dan hal ini akan mengakibatkan estimasi menjadi lebih *flat* dan tidak kompleks (Vijayakumar, 1999). Menurut Chai (2011) apabila nilai parameter ϵ semakin besar maka presisi dari suatu polaregresi akan semakin rendah dan semakin kecil *support vector* nya. Berdasarkan informasi tersebut, dengan demikian semakin kecil nilai parameter ϵ , maka akan semakin baik. Pada hasil pengujian rentang parameter ini, rata-rata nilai *cost* terkecil diperoleh pada rentang parameter 0,00001-0,01.

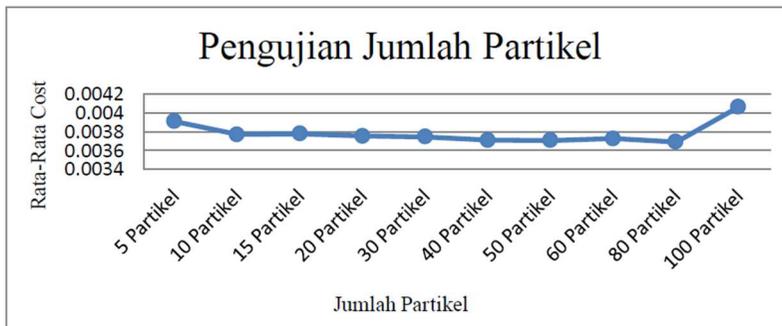
5. Parameter C

Rentang parameter σ , λ , cLR dan ϵ yang digunakan berdasarkan hasil pengujian parameter σ , λ , cLR dan ϵ sebelumnya pada point 1, 2, 3 dan 4. Sedangkan rincian parameter lain yang akan digunakan berdasarkan pengujian awal.



Gambar 3. 5 Grafik Pengujian Rentang Parameter C Metode PSOSVR

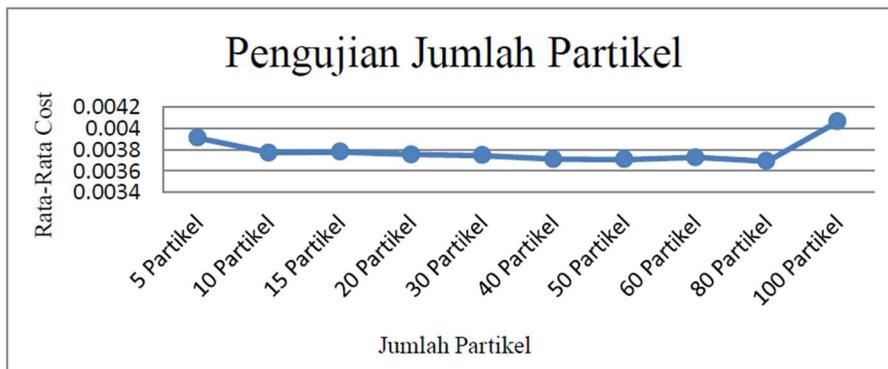
Berdasarkan Gambar 3.5 diperoleh informasi bahwa semakin besar batas atas pada rentang parameter C, maka nilai rata-rata *cost* cenderung semakin kecil. Nilai parameter C yang baik adalah nilai parameter C yang tidak terlalu kecil sehingga menjamin error yang dihasilkan model regresi tidak terlalu besar (Chai, 2011). Pada pengujian rentang parameter studi kasus penelitian ini, rata-rata nilai *cost* terkecil diperoleh pada rentang parameter 0,01-1500.



Gambar 3. 6 Grafik Pengujian Jumlah Partikel 5-100 Metode PSOSVR

Pengujian Jumlah Partikel

Pengujian jumlah partikel ini digunakan untuk menentukan banyaknya jumlah partikel yang optimal dan hasil pengujian terbaik akan digunakan dalam prediksi harga batubara acuan. Rentang parameter σ , λ , cLR, ϵ dan C yang digunakan berdasarkan hasil pengujian rentang parameter sebelumnya.



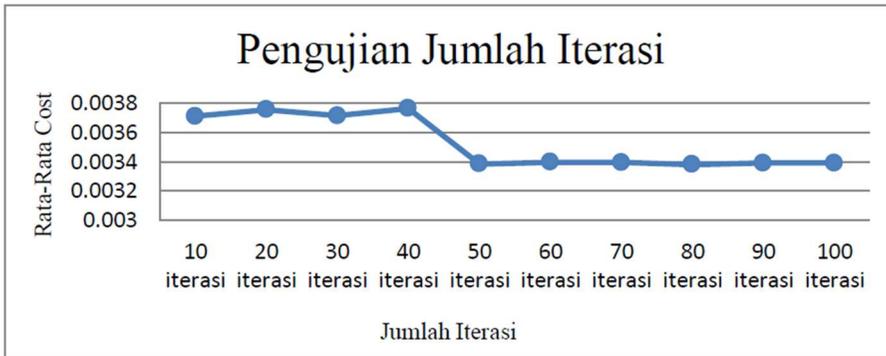
Gambar 3.7 Grafik Waktu Komputasi 5-100 Partikel Metode PSOSVR

Berdasarkan Gambar 3.6 dan Gambar 3.7 diperoleh informasi, bahwa nilai rata-rata *cost* terendah diperoleh ketika jumlah partikelnya 80. Selain itu diketahui bahwa semakin banyak jumlah partikel yang digunakan maka semakin rendah nilai rata-rata *cost*nya karena lingkup ruang solusi yang semakin besar. Namun, semakin banyak jumlah partikel yang digunakan mengakibatkan waktu komputasi semakin kompleks sehingga membutuhkan waktu yang cukup lama untuk menyelesaikan komputasi. Pada studi kasus penelitian ini, direkomendasikan untuk menggunakan sebanyak 40 jumlah partikel, karena setelah 40 partikel tidak ada lagi perubahan yang signifikan dan waktu komputasi yang cukup kecil.

3.3.2 Pengujian Jumlah Iterasi

Pengujian jumlah iterasi ini dilakukan dengan tujuan untuk menentukan banyaknya jumlah iterasi yang optimal dan hasil pengujian terbaik akan digunakan dalam prediksi harga batubara acuan. Rentang parameter σ , λ , cLR , ϵ dan C yang digunakan berdasarkan hasil pengujian rentang parameter sebelumnya. Dan jumlah partikel yang digunakan berdasarkan hasil pengujian jumlah partikel sebelumnya.

Berdasarkan Gambar 3.8 diperoleh informasi bahwa semakin banyak jumlah iterasi maka semakin rendah nilai rata-rata *cost* yang dihasilkan, namun pada jumlah iterasi tertentu nilai rata-rata *cost* akan mengalami konvergensi. Penentuan jumlah iterasi yang optimal juga bergantung pada kasusnya, dan untuk studi kasus pada penelitian ini, ternyata ketika dilakukan iterasi sebanyak 80 menghasilkan solusi yang terbaik. Apabila jumlah maksimum iterasi terlalu sedikit, pencarian solusi mungkin akan berhenti lebih awal.



Gambar 3.8 Grafik Pengujian Jumlah Iterasi Metode PSOSVR

Sebaliknya apabila jumlah maksimum iterasi terlalu besar, maka kemungkinan terjadi penambahan kompleksitas komputasi yang tidak diperlukan ketika jumlah iterasi maksimum menjadi kondisi pemberhentian komputasi (Engelbrecht, 2007).

3.2 Optimasi dan Prediksi Menggunakan Metode PSOSVR

Setelah rangkaian pengujian rentang parameter, pengujian jumlah partikel dan pengujian jumlah iterasi dilakukan maka diperoleh informasi rentang parameter, jumlah partikel dan jumlah iterasi terbaik, yang akan digunakan dalam proses optimasi PSOSVR untuk memperoleh nilai parameter terbaik. Selanjutnya nilai parameter terbaik hasil optimasi tersebut akan digunakan dalam memprediksi harga batubara acuan. Nilai parameter hasil optimasi berdasarkan hasil pengujian rentang parameter sebelumnya tersaji pada tabel 3.2.

Tabel 3. 2 Hasil Optimasi Parameter Menggunakan Metode PSOSVR

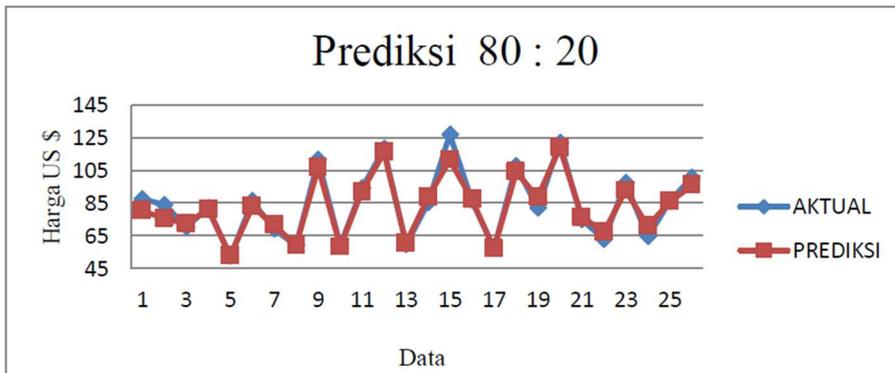
C	Epsilon	Sigma	cLR	Lambda
482.94292	0.00859	1.17702	1.07747	42.89886

Hal yang selanjutnya dilakukan setelah nilai parameter optimal hasil dari optimasi diperoleh, yaitu melakukan proses memprediksi harga batubara acuan. Tingkat akurasi dari proses prediksi ini diperoleh dengan melihat dari perbandingan harga batubara acuan hasil prediksi dengan harga batubara acuan yang sebenarnya. Selain itu juga, tingkat akurasi dapat dilihat dari nilai error yaitu nilai *Mean Absolute Percentage Error* (MAPE), dimana hasil prediksi semakin akurat pada saat nilai error semakin kecil. Berikut hasil prediksi harga batubara acuan dengan perbandingan 80% data latih dan 20%

data uji tersaji pada Tabel 3.3 dan grafiknya pada Gambar 3.9.

Tabel 3.3 Hasil Prediksi Menggunakan Metode PSOSVR

80 Data Latih 20 Data Uji					
DATA	AKTUAL	PREDIKSI	DATA	AKTUAL	PREDIKSI
1	87.55	80.21692	14	85.33	88.49192
2	83.97	75.73646	15	127.05	111.58906
3	70.29	72.41658	16	86.58	87.2202
4	81.9	81.07883	17	57.39	57.07066
5	52.32	52.68551	18	107.83	103.95143
6	86.21	83.05114	19	81.86	88.52426
7	69.07	71.67567	20	122.02	118.94049
8	59.16	58.96417	21	74.81	76.47439
9	111.58	106.827	22	62.83	67.09465
10	59.14	58.35437	23	97.22	92.80335
11	93.99	92.11512	24	64.48	70.9772
12	118.24	116.14013	25	86.04	85.79942
13	59.59	60.44724	26	100.69	95.78361



Gambar 3. 9 Grafik Prediksi Menggunakan Metode PSOSVR

Setelah data hasil prediksi diperoleh, selanjutnya untuk mengetahui tingkat keakuratan antara data aktual dengan data hasil prediksi, maka dihitung dengan menggunakan MAPE sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| * 100\%$$

$$MAPE = \frac{1,01686}{26} * 100\%$$

$$MAPE = 3,911\%$$

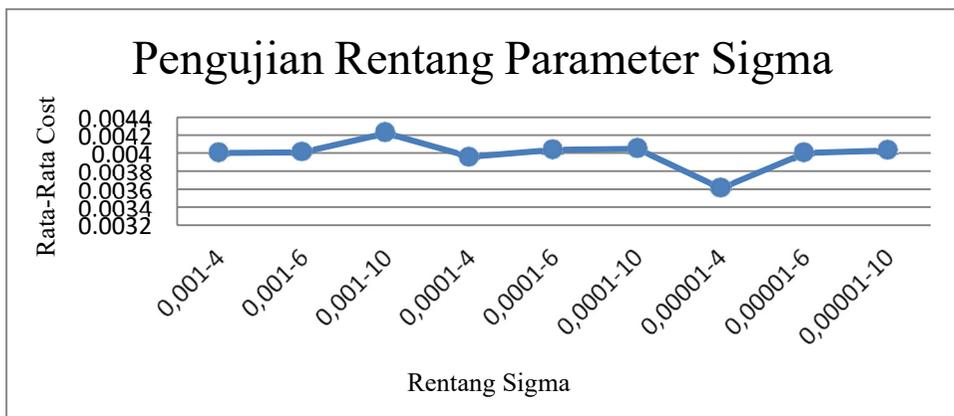
Karena nilai MAPE kurang dari 10% yaitu 3,911%, maka berdasarkan kriteria yang telah dikemukakan sebelumnya dapat dikatakan bahwa, parameter yang dioptimasi menggunakan PSOSVR sangat baik untuk digunakan dalam memprediksi harga batubara acuan.

3.3 Optimasi dan Prediksi Menggunakan Metode PSOSVR

3.3.4 Pengujian Rentang Parameter

Pengujian rentang parameter ini dilakukan untuk memperoleh rentang parameter yang optimal dari parameter λ (*lamda*), ϵ (*epsilon*), cLR (*learning rate*), C (kompleksitas), dan σ (*sigma*). Selain itu pengujian rentang parameter dilakukan dengan tujuan untuk mendapatkan hasil pengujian nilai parameter terbaik yang akan digunakan dalam optimasi parameter dengan metode PSOSVR dan prediksi harga batubara acuan. Nilai rentang parameter tersebut akan berpengaruh terhadap besar nilai parameternya. Untuk setiap pengujian diulang sebanyak 10 kali. Pengujian pertama dilakukan dengan menggunakan rentang parameter awal yang diperoleh berdasarkan hasil-hasil penelitian sebelumnya, yang nilainya terdapat pada sub bab 3.3.1.

1. Parameter Sigma

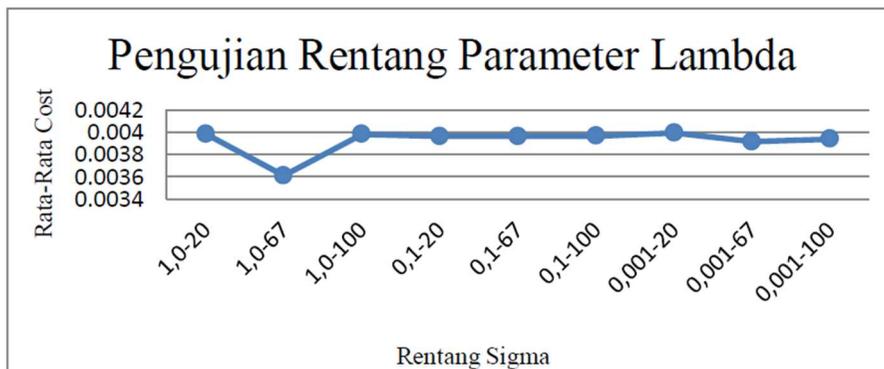


Gambar 3.10 Grafik Pengujian Rentang Parameter σ Metode IPSOSVR

Berdasarkan Gambar 3.10, dapat diperoleh informasi bahwa nilai rata-rata *cost* cenderung naik mengikuti batas atas yang semakin membesar. Pada pengujian ini rentang parameter σ yang paling optimal adalah pada rentang 0,00001-4.

2. Parameter Lambda

Rentang parameter σ yang digunakan berdasarkan hasil pengujian parameter σ sebelumnya pada point 1. Sedangkan rincian parameter lain yang akan digunakan berdasarkan pengujian awal.

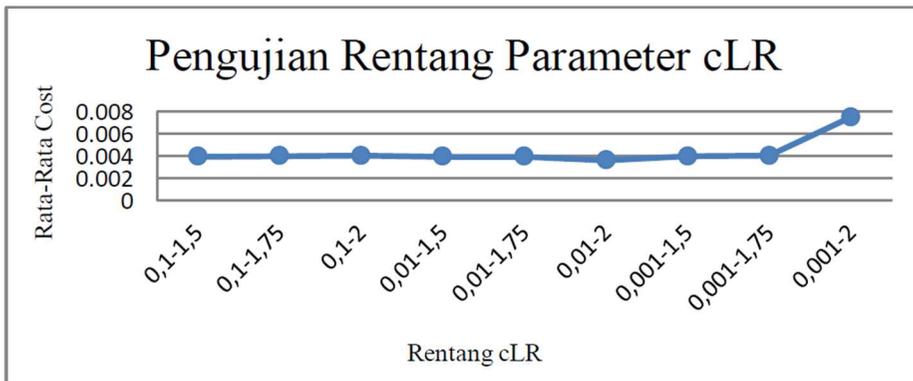


Gambar 3. 11 Grafik Pengujian Rentang Parameter λ Metode IPSOSVR

Berdasarkan Gambar 3.11. Diketahui bahwa nilai rata-rata *cost* terendah diperoleh pada rentang 1-67. Pada umumnya, semakin besar rentang parameter λ semakin baik keakuratan regresinya. Tetapi, jika terlalu besar rentang parameter λ akan memberikan efek yaitu mengakibatkan rendahnya kecepatan konvergensi yang akan membutuhkan komputasi yang lebih lama dan membuat proses tidak stabil (Vijayakumar, 1999).

3. Parameter cLR

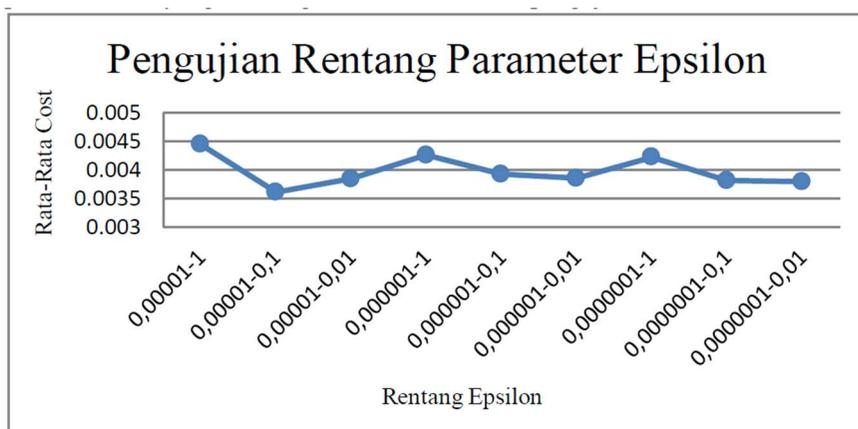
Rentang parameter σ dan λ yang digunakan berdasarkan hasil pengujian parameter σ dan λ sebelumnya pada point 1 dan 2. Sedangkan rincian parameter lain yang akan digunakan berdasarkan pengujian awal.



Gambar 3.12 Grafik Pengujian Rentang Parameter cLR Metode IPSOSVR Berdasarkan Gambar 3.12 diperoleh informasi bahwa, rata-rata nilai *cost* terkecil diperoleh pada rentang parameter 0,01-2. Parameter cLR yang berada pada rentang tersebut dapat menghasilkan *learning rate* (γ) yang mampu membangun model dengan tingkat akurasi yang tinggi. Semakin kecil nilai *learning rate* (γ), maka proses *learning* akan lebih lama namun mendapatkan hasil konvergen (Vijayakumar, 1999).

4. Parameter Epsilon

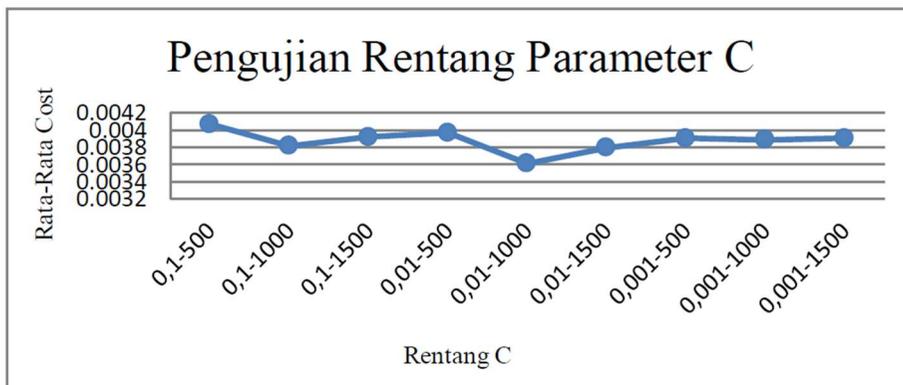
Rentang parameter σ , λ dan cLR yang digunakan berdasarkan hasil pengujian parameter σ , λ dan cLR sebelumnya pada point 1, 2 dan 3. Sedangkan rincian parameter lain yang akan digunakan berdasarkan pengujian awal.



Gambar 3.13 Grafik Pengujian Rentang Parameter ϵ Metode IPSOSVR

5. Parameter C

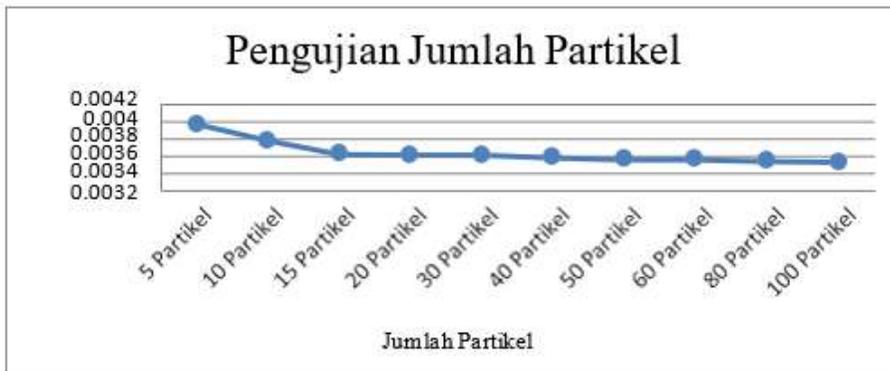
Rentang parameter σ , λ , cLR dan ϵ yang digunakan berdasarkan hasil pengujian parameter σ , λ , cLR dan ϵ sebelumnya pada point 1, 2, 3 dan 4. Sedangkan rincian parameter lain yang akan digunakan berdasarkan pengujian awal. Berdasarkan Gambar 3.14 diperoleh informasi bahwa semakin besar batas atas pada rentang parameter C, maka nilai rata-rata *cost* cenderung semakin kecil. Nilai parameter C yang baik adalah nilai parameter C yang tidak terlalu kecil sehingga menjamin error yang dihasilkan model regresi tidak terlalu besar (Chai,2011). Pada pengujian rentang parameter studi kasus penelitian ini, rata-rata nilai *cost* terkecil diperoleh pada rentang parameter 0,01-1000.



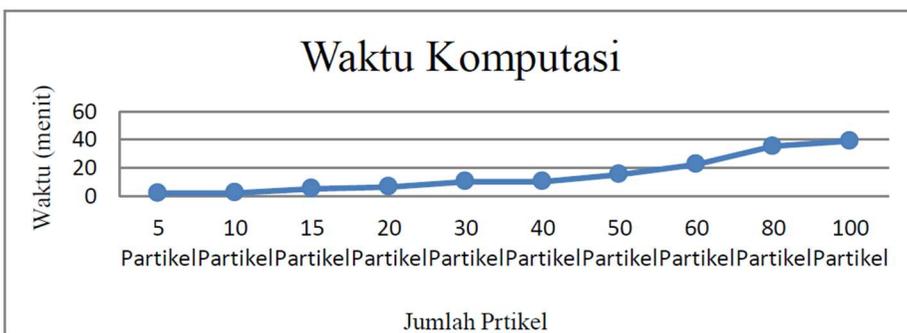
Gambar 3.14 Grafik Pengujian Rentang Parameter C Metode IPSOSVR

3.3.5 Pengujian Jumlah Partikel

Pengujian jumlah partikel ini digunakan untuk menentukan banyaknya jumlah partikel yang optimal dan hasil pengujian terbaik akan digunakan dalam prediksi harga batubara acuan. Rentang parameter σ , λ , cLR, ϵ dan C yang digunakan berdasarkan hasil pengujian rentang parameter sebelumnya.



Gambar 3.15 Grafik Pengujian Jumlah Partikel 5-100 Metode IPSOSVR



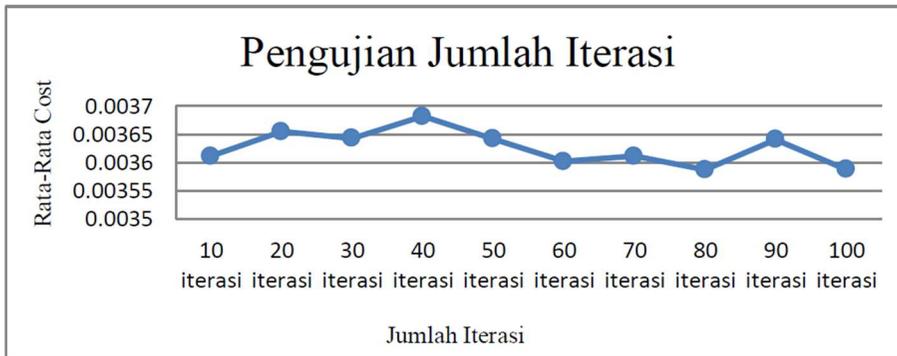
Gambar 3.16 Grafik Waktu Komputasi 5-100 Partikel Metode IPSOSVR

Berdasarkan Gambar 3.15 dan Gambar 3.16 diperoleh informasi, bahwa nilai rata-rata *cost* terendah diperoleh ketika jumlah partikelnya 100. Selain itu diketahui bahwa semakin banyak jumlah partikel yang digunakan maka semakin rendah nilai rata-rata *cost*-nya karena lingkup ruang solusi yang semakin besar. Namun, semakin banyak jumlah partikel yang digunakan mengakibatkan waktu komputasi semakin kompleks sehingga membutuhkan waktu yang cukup lama untuk menyelesaikan komputasi. Pada studi kasus penelitian ini, direkomendasikan untuk menggunakan sebanyak 40 jumlah partikel, karena setelah 20 partikel tidak ada lagi perubahan yang signifikan dan waktu komputasi yang cukup kecil.

3.3.6 Pengujian Jumlah Iterasi

Pengujian jumlah iterasi ini dilakukan dengan tujuan untuk menentukan banyaknya jumlah iterasi yang optimal dan hasil pengujian terbaik akan digunakan dalam prediksi harga batubara acuan. Rentang parameter σ , λ , cLR, ϵ dan C yang digunakan berdasarkan hasil pengujian rentang parameter

sebelumnya. Dan jumlah partikel yang digunakan berdasarkan hasil pengujian jumlah partikel sebelumnya.



Gambar 3.17 Grafik Pengujian Jumlah Iterasi Metode IPSOSVR

Berdasarkan Gambar 3.17 diperoleh informasi bahwa semakin banyak jumlah iterasi maka semakin rendah nilai rata-rata *cost* yang dihasilkan, namun pada jumlah iterasi tertentu nilai rata-rata *cost* akan mengalami konvergensi. Penentuan jumlah iterasi yang optimal juga bergantung pada kasusnya, dan untuk studi kasus pada penelitian ini, ternyata ketika dilakukan iterasi sebanyak 80 menghasilkan solusi yang terbaik. Apabila jumlah maksimum iterasi terlalu sedikit, pencarian solusi mungkin akan berhenti lebih awal. Sebaliknya apabila jumlah maksimum iterasi terlalu besar, maka kemungkinan terjadi penambahan kompleksitas komputasi yang tidak diperlukan ketika jumlah iterasi maksimum menjadi kondisi pemberhentian komputasi (Engelbrecht, 2007).

3.4 Optimasi dan Prediksi Menggunakan Metode IPSOSVR Asdas

Setelah rangkaian pengujian rentang parameter, pengujian jumlah partikel dan pengujian jumlah iterasi dilakukan maka diperoleh informasi rentang parameter, jumlah partikel dan jumlah iterasi terbaik, yang akan digunakan dalam proses optimasi PSOSVR untuk memperoleh nilai parameter terbaik. Selanjutnya nilai parameter terbaik hasil optimasi tersebut akan digunakan dalam memprediksi harga batubara acuan. Nilai parameter hasil optimasi berdasarkan hasil pengujian rentang parameter sebelumnya tersaji pada Tabel 3.4.

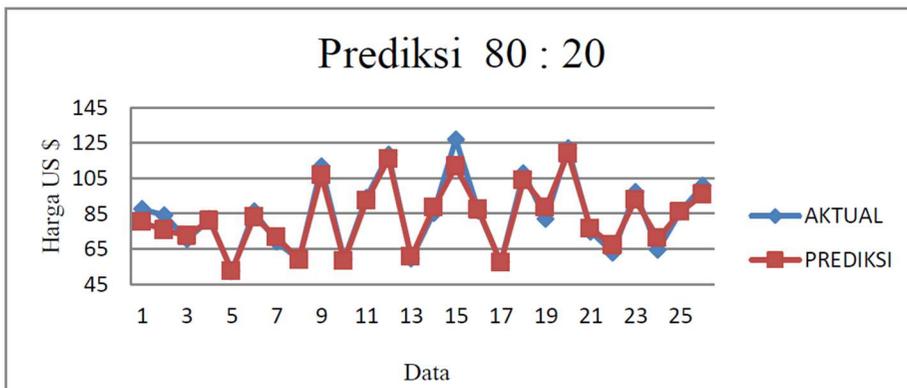
Tabel 3.4 Hasil Optimasi Parameter Menggunakan Metode PSOSVR

C	Epsilon	Sigma	Clr	Lambda
495.95761	0.00934	1.10025	0.96756	3.42606

Hal yang selanjutnya dilakukan setelah nilai parameter optimal hasil dari optimasi diperoleh, yaitu melakukan proses memprediksi harga batubara acuan. Tingkat akurasi dari proses prediksi ini diperoleh dengan melihat dari perbandingan harga batubara acuan hasil prediksi dengan harga batubara acuan yang sebenarnya. Selain itu juga, tingkat akurasi dapat dilihat dari nilai error yaitu nilai *Mean Absolute Percentage Error* (MAPE), dimana hasil prediksi semakin akurat pada saat nilai error semakin kecil. Berikut hasil prediksi harga batubara acuan dengan perbandingan 80% data latih dan 20% data uji tersaji pada Tabel 3.5 dan grafiknya pada Gambar 3.18.

Tabel 3.5 Hasil Prediksi Menggunakan Metode IPSOSVR
80 Data Latih 20 Data Uji

DATA	AKTUAL	PREDIKSI	DATA	AKTUAL	PREDIKSI
1	87.55	80.20613	14	85.33	88.49851
2	83.97	75.69793	15	127.05	111.60287
3	70.29	72.40673	16	86.58	87.24143
4	81.9	81.04406	17	57.39	57.0747
5	52.32	52.66683	18	107.83	103.95065
6	86.21	83.03108	19	81.86	88.52268
7	69.07	71.66154	20	122.02	118.91213
8	59.16	58.98831	21	74.81	76.48032
9	111.58	106.82334	22	62.83	67.1142
10	59.14	58.36218	23	97.22	92.7955
11	93.99	92.12054	24	64.48	70.95766
12	118.24	116.13615	25	86.04	85.79255
13	59.59	60.48262	26	100.69	95.78135



Gambar 3.18 Grafik Prediksi Menggunakan Metode IPSOSVR

Setelah data hasil prediksi diperoleh, selanjutnya untuk mengetahui tingkat keakuratan antara data aktual dengan data hasil prediksi, maka dihitung dengan menggunakan MAPE sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| * 100\%$$

$$MAPE = \frac{1,01816}{26} * 100\%$$

$$MAPE = 3,916\%$$

Karena nilai MAPE kurang dari 10% yaitu 3,916%, maka berdasarkan kriteria yang telah dikemukakan sebelumnya dapat dikatakan bahwa, parameter yang dioptimasi menggunakan IPSOSVR sangat baik untuk digunakan dalam memprediksi harga batubara acuan.

4. PENUTUP

Berdasarkan hasil dan pembahasan, maka dapat disimpulkan :

1. Metode PSOSVR dan IPSOSVR dapat diterapkan dalam memprediksi harga batubara acuan. Dengan tahapan sebagai berikut: (1) menentukan parameter awal dan data masukan yang akan digunakan, (2) melakukan normalisasi data menggunakan metode normalisasi min-max, (3) melakukan proses optimasi PSO dan optimasi IPSO menggunakan data hasil normalisasi, (4) melakukan proses prediksi menggunakan metode SVR berdasarkan parameter hasil optimasi.
2. Berdasarkan hasil output program aplikasi proses optimasi menggunakan metode PSOSVR diperoleh hasil yaitu nilai parameter C sebesar 482,94292, nilai parameter ε sebesar 0,00859, nilai parameter σ sebesar

1,17702, nilai parameter cLR sebesar 1,07747, dan nilai parameter λ sebesar 42,89886. Untuk proses optimasi menggunakan metode IPSOSVR diperoleh hasil yaitu nilai parameter C sebesar 495,95761, nilai parameter ε sebesar 0,00934, nilai parameter σ sebesar 1,10025, nilai parameter cLR sebesar 0,96756, dan nilai parameter λ sebesar 3,42606. Perbandingan hasil prediksi harga batubara acuan dengan data aslinya tidak jauh berbeda. Dengan ketuan 80% data latih dan 20% data uji diperoleh nilai MAPE untuk metode PSOSVR sebesar 3,911%, nilai MAPE untuk metode IPSOSVR sebesar 3,916%. Dapat dikatakan metode PSOSVR dan metode IPSOSVR sudah sangat baik digunakan untuk peramalan harga batubara acuan.

5. DAFTAR PUSTAKA

- Chai, Y. (2011). A Coal Mine Gas Concentration Prediction Method based on Particle Swarm Optimization Support Vector Regression. *IEEE*, 334-337.
- Cholissodin, I., & Riyandani, I. (2016). *Swarm Intelligence*. Malang: Fakultas IlmuKomputer, Universitas Brawijaya.
- Ditjen Minerba Kementerian ESDM. (2019).
- Engelbrecht, A. P. (2007). *Computational Intelligence: An Introduction 2nd ed.*, West Sussex: John Wiley & Sons Ltd.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning Second*. New York: Springer-Verlag.
- Hsieh, H.-I, Lee, T.-P, & Lee, T.-S. (2011). A Hybrid Particle Swarm Optimization and Support Vector Regression Model for Financial Time Series Forecasting. *Int. Journal of Business Administration*, 2, 48-56.
- Kennedy, J., & Eberhart, R. (1995). Particle Swarm Optimization. *Neural Networks., Proceedings., IEEE Int. Conf*, 4, pp. 1942– 1948.
- Khair, U., Fahmi, H., Al Hakim, S., & Rahim, R. (2017, December). Forecasting error calculation with mean absolute deviation and mean absolute percentage error. In *Journal of Physics: Conference Series* (Vol. 930, No. 1, p. 012002). IOP Publishing.
- Marini, F., & Walczak, B. (2015). Particle swarm optimization (PSO). A tutorial. *IEEE Chemometrics and Intelligent Laboratory Systems*, 13.
- Novitasari, D., Cholissodin, I., & Mahmudy, W. F. (2016). Hybridizing PSO with SA for Optimizing SVR Applied to Software Effort Estimation. *TELKOMNIKA*, pp. 245-253.

- Qasim, S. Q., & Algamal, Z. Y. (2018). Feature Selection Using Particle Swarm Optimization-based Logistic Regression Model. *Chemometrics and Intelligent Laboratory System*, 182, Pp 41-46.
- Saputro, F. D., (2017). Penerapan Support Vector Regression Dengan Optimasi PSO Dalam Memprediksi Harga Gabah. (Doctoral dissertation, Universitas Komputer Indonesia).
- Smola, A. J., & Scholkopf, B. (2004). A Tutorial On Support Vector Regression. *The Journal of Statistics and Computing*, 14(3) Pp. 199-222.
- Vapnik, V. (1999). An Overview of Statistical Learning Theory. *IEEE Transactionson Neural Networks*, 10(5), pp.988–999.
- Vijayakumar, S. (1999). Sequential Support Vector Classifiers and Regression. *InProceedings of International Conference on Soft Computing (SOCO '99)*, 610–619.
- Zhang, K., Qiu, B., & Mu, D. (2016). Low-carbon Logistics Distribution Route Planning With Improved Particle Swarm Optimization Algorithm. *School of Economics and Management Beijing Jiaotong University Beijing, China*.
- Zou, Jifeng, Chenlong, L., & Qiao, L. (2015). *Fault Prediction Method based onSVR of Improved PSO*. China: School of Information Science and Engineering, Shenyang Ligong University, Shenyang 110159.