

Optimalisasi Parameter Support Vector Regression dengan Algoritma Random search dan Algoritma Grid search

Luthfi Alleyda Fadhlullah^{a,1}, Joko Purwadi^{a,2*}

^a Departement Mathematics, Faculty of Applied Sciences and Tchnology, Universitas Ahmad Dahlan Yogyakarta;

^b Departement Mathematics, Faculty of Applied Sciences and Tchnology, Universitas Ahmad Dahlan Yogyakarta;

¹ luthfi2000015026@webmail.uad.ac.id ; ^{2*} joko@math.uad.ac.id ;

*Correspondent Author

Received:

Revised:

Accepted:

KATAKUNCI

Grid search
Mean Squared Error (MSE);
Random Search
Root Mean Square Error (RMSE)
SVR

KEYWORDS

Grid search
Mean Squared Error (MSE);
Random Search
Root Mean Square Error (RMSE)
SVR

ABSTRAK

Penelitian ini membahas tentang metode Support Vector Regression (SVR) dengan algoritma optimasi Random search dan Grid search. Tujuan penelitian ini untuk mengevaluasi kinerja metode SVR dalam memprediksi harga beras di wilayah Jawa Barat, dan untuk membandingkan efektivitas dua algoritma optimasi, yaitu Random search dan Grid search. Hasil yang diperoleh menunjukkan bahwa kedua metode optimasi memberikan prediksi yang baik dan mampu mengikuti pola data asli. Pada model SVR-Random search, nilai MSE untuk harga beras premium adalah 0.0005954 dan RMSE 0.0230852, sedangkan untuk beras medium adalah 0.0014819 dan RMSE 0.0355231. sementara pada model SVR-Grid search, nilai MSE untuk harga beras premium adalah 0.0005966 dan RMSE 0.0231990, sedangkan untuk beras medium adalah 0.0013369 dan RMSE 0.0328463.

Optimization of Support Vector Regression Parameters with Random search Algorithm and Grid search Algorithm

This research discusses the Support Vector Regression (SVR) method with Random search and Grid search optimization algorithms. The purpose of this study is to evaluate the performance of the SVR method in predicting rice prices in the West Java region, and to compare the effectiveness of two optimization algorithms, namely Random search and Grid search. The results obtained show that both optimization methods provide good predictions and can follow the original data pattern. In the SVR-Random search model, the MSE value for premium rice price is 0.0005954 and RMSE 0.0230852, while for medium rice is 0.0014819 and RMSE 0.0355231. while in the SVR-Grid search model, the MSE value for premium rice price is 0.0005966 and RMSE 0.0231990, while for medium rice is 0.0013369 and RMSE 0.0328463.

This is an open-access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Pendahuluan

Prediksi merupakan perhitungan yang mengkaji kondisi masa lalu untuk memprediksi atau memperkirakan kondisi di masa depan. Salah satu metode pembelajaran mesin yang sering digunakan untuk melakukan prediksi adalah *Support Vector Regression* (SVR). Metode ini bekerja dengan menemukan *hyperplane* yang paling cocok untuk mengurangi kesalahan prediksi sambil tetap mempertahankan margin yang paling besar di sekitar *hyperplane* tersebut. Keunggulan SVR termasuk kemampuan untuk menangani outlier dan data dengan dimensi tinggi. Hal ini membuatnya populer dalam banyak aplikasi seperti prediksi harga saham, pemodelan cuaca, dan prediksi harga rumah. Meskipun terdapat keunggulan, SVR juga memiliki kelemahan. Proses parameter yang tepat dan data yang besar dapat menjadi rumit, dan kinerja SVR menjadi sensitif terhadap pengaturan parameter. Oleh karena itu, perlu mendalami prinsip dibalik SVR serta praktik terbaik sehingga penerapannya sangat penting untuk mendapatkan hasil yang optimal. Dalam pengembangan model machine learning, parameter yang optimal sering menjadi masalah utama. Parameter yang tepat dapat berdampak pada kinerja model, serta akurasi prediksi, waktu pelatihan, dan penggunaan sumber daya komputasi. Salah satu pendekatan yang digunakan dalam menentukan parameter terbaik adalah algoritma *random search*.

Beberapa penelitian yang telah dilakukan antara lain terkait penggunaan SVR dalam prediksi penggunaan energi Listrik dari sebuah system berbasis web dengan optimasi *grid search* [1]. Penelitian oleh Hentiana (2022) membahas implementasi SVR untuk prediksi persediaan sarang walet dan memberikan MSE yang relative kecil [2]. Selanjutnya penelitian yang dilakukan oleh Subiyanto, dkk (2023), mempelajari kejadian penyakit cacar monyet dengan pendekatan SVR berbasis Kernel Radial basis [3]. Penerapan SVR dalam prediksi harga emas juga pernah dilakukan oleh Novi Selviani (2023) yang dalam penelitiannya menggunakan SVR untuk prediksi harga emas dengan menggunakan optimasi PSO [4]. Penelitian terhadap prediksi harga emas juga dilakukan oleh Anisa (2022), dengan pendekatan algoritma SVD dan Regresi Linier [5]. Pada tahun 2020 model SVR juga digunakan untuk melakukan prediksi terhadap jumlah pengguna dan ukuran kereta api [6].

Produksi dan perdagangan beras memiliki peran penting dalam perekonomian negara, terutama negara Indonesia disektor pertanian padi. Dunia usaha yang semakin pesat mengharuskan setiap distributor mampu mampu memprediksi berbagai kemungkinan yang akan terjadi dimasa depan. Masalah utama yang dihadapi oleh pemilik usaha beras adalah persaingan pasar, perubahan harga dan pasokan, manajemen stok ini sangat penting untuk mempengaruhi cash flow dan keuntungan, pemasan dan branding, dan kualitas produk. Kualitas produk ini merupakan tantangan yang dimiliki oleh pemilik usaha beras karena mereka harus bisa mempertahankan kualitas produknya. Apabila pemilik usaha beras tidak bisa mempertahankan kualitasnya dapat berdampak buruk pada reputasi bisnis, membuat pelanggan kecewa, dan berpotensi untuk kehilangan pendapatan.

Metode

Support Vector Regression

Metode SVR dapat menyelesaikan permasalahan linier dan nonlinier dengan memanfaatkan konsep kerugian simetris. Nilai ϵ menunjukkan tingkat toleransi antara

input prediksi dan output aktual, serta besarnya *support vector* [18]. Misalkan terdapat m data latih dengan $(x_i, y_i) = 1, 2, 3, \dots, m$ dimana x_i merupakan vektor masukan $x = \{x_1, x_2, \dots, x_n\} \subseteq \mathbb{R}^n$ dan keluaran skalar $y = \{y_1, \dots, y_n\} \subseteq \mathbb{R}$ dan m adalah banyaknya data latih. SVR bertujuan untuk mengidentifikasi fungsi $f(x)$ dengan deviasi tertinggi ϵ dari target aktual y_i , untuk semua data latih. Jika nilai ϵ bernilai 0 maka diperoleh regresi sederhana. Oleh karena itu, fungsi *hyperplane* dapat diringkas sebagai berikut:

$$f(x) = \mathbf{w} \cdot \mathbf{x}_i + b \quad (2.7)$$

dengan $x_i = (x_1, x_2, \dots, x_n)^T \in \mathbb{R}^n$

dimana

\mathbf{w} = nilai bobot *support vector* tegak lurus *hyperplane*

\mathbf{x}_i = nilai x ke - i

b = bias

Hasil terbaik dari fungsi regresi $f(x)$ diperoleh dengan meminimalkan \mathbf{w} dan memaksimalkan solusi optimal. Masalah ini dapat diselesaikan dengan menggunakan optimasi cembung dengan menggunakan rumus berikut:

Minimalkan:

$$\frac{1}{2} \|\mathbf{w}\|^2 \quad (2.8)$$

Fungsi Tujuan:

$$y_i - \mathbf{w} \cdot \mathbf{x}_i - b \leq \epsilon$$

$$\mathbf{w} \cdot \mathbf{x}_i + b - y_i \leq \epsilon$$

Dalam persamaan (2.8), ada kasus dimana kesalahan menyebabkan batas ϵ . Permasalahan ini dapat diselesaikan dengan menggunakan *soft margin* yang disebut juga dengan variabel slack ξ_i, ξ_i^* untuk memperhitungkan kendala yang kurang ideal dalam permasalahan optimasi dengan memberikan penalti pada data yang tidak memenuhi syarat. Perhatikan kendala yang dimaksud. Penalti dinotasikan dengan C , maka rumus diatas dapat dibandingkan dengan rumus berikut:

Minimalkan:


$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=0}^n (\xi_i + \xi_i^*) \quad (2.9)$$

Fungsi tujuan:

$$y_i - \mathbf{w} \cdot \mathbf{x}_i - b \leq \epsilon + \xi_i$$

$$\mathbf{w} \cdot \mathbf{x}_i + b - y_i \leq \epsilon + \xi_i^*$$

$$\xi_i + \xi_i^* \geq 0 \quad \text{dimana } i = 1, 2, 3, \dots, i$$



Gambar 2.4 Konsep SVR

Konstanta $C > 0$ mewakili batas atas toleransi fungsi $f(x)$ dan beberapa deviasi signifikan dalam kesalahan yang diperbolehkan dari batas ϵ . Setiap penyimpangan lebih dari ϵ akan disebut penalti sama dengan C . Fungsi yang disebut Loss merepresentasikan hubungan antara kesalahan dan penalty pada kesalahan dalam bentuk ξ . Salah satu fungsi yang digunakan untuk menyoroti perbedaan antara nilai prediksi dan nilai actual adalah *Loss Function*. *Loss Function* dapat dituliskan sebagai berikut

$$L_{\epsilon}(y_i, f(x_i)) = \begin{cases} 0 & \text{untuk } |y_i - f(x_i)| < \epsilon \\ |y_i - f(x_i)| - \epsilon & \text{lainnya} \end{cases} \quad (2.10)$$

Nilai ϵ yang kecil dengan nilai variabel slack yang tinggi akan meningkatkan akurasi pendekatan. Sebaliknya, nilai ϵ yang tinggi dikombinasikan dengan nilai variabel slack yang rendah akan mengurangi keakuratan perkiraan. Nilai ekstrim dari variabel slack dapat mengakibatkan kegagalan eksperimental dalam uji penetrasi.

Hubungan antara parameter \mathbf{w} dan b menjadi dasar pemrogram kuadrat, yaitu meminimalkan fungsi kuadrat dengan kondisi garis yang tumpang tindih. Campuran ini dapat diatur menggunakan *Langrange Multiplier*. Solusi optimal persamaan (2.5) dan Solusi Kendala (2.6) dapat diselesaikan dengan menerapkan *Langrange Multiplier* pada persamaan berikut:

$$L = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) - \sum_{i=1}^m \lambda_i \xi_i + \lambda_i^* \xi_i^* \quad (2.11)$$

$$- \sum_{i=1}^m \alpha_i (\epsilon + \xi_i - y_i + (\mathbf{w} \cdot \mathbf{x}_i) + b)$$

$$- \sum_{i=1}^m \alpha_i^* (\epsilon + \xi_i^* - y_i + (\mathbf{w} \cdot \mathbf{x}_i) + b)$$

dengan,

L = Fungsi Lagrange

C = nilai penalti

\mathbf{w} = nilai bobot berdimensi i

b = bias

ϵ = nilai toleransi

ξ_i = variabel slack

ξ_i^* = variabel slack untuk Solusi optimal
 y_i = output skalar

Dengan $\alpha_i, \alpha_i^*, \lambda_i, \lambda_i^*$ adalah *lagrange* koefisien. Dengan menggunakan proses pemodelan turunan Parsial L , diperoleh Solusi terbaik w, b, ξ_i, ξ_i^*

$$1. \frac{\partial L}{\partial w} = 0$$

$$w - \sum_{i=1}^m (\alpha_i - \alpha_i^*) x_i = 0$$

$$w = \sum_{i=1}^m (\alpha_i - \alpha_i^*) x_i \quad (2.12)$$

$$2. \frac{\partial L}{\partial b} = 0$$

$$\sum_{i=1}^m \alpha_i - \sum_{i=1}^m \alpha_i^* = 0 \quad (2.13)$$

$$3. \frac{\partial L}{\partial \xi_i} = 0$$

$$C - \lambda_i - \alpha_i = 0$$

$$C = \lambda_i + \alpha_i \quad (2.14)$$

$$4. \frac{\partial L}{\partial \xi_i^*} = 0$$

$$C - \lambda_i^* - \alpha_i^* = 0$$

$$C = \lambda_i^* + \alpha_i^* \quad (2.15)$$

Lalu substitutikan persamaan (2.12), (2.13), (2.14), dan (2.15) kedalam persamaan (2.11) sehingga diperoleh

$$L(\alpha_i, \alpha_i^*) = \frac{1}{2} \sum_{i,j=1}^m (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) x_i x_j$$

$$+ \sum_{i=1}^m y_i (\alpha_i - \alpha_i^*) - \epsilon \sum_{i=1}^m (\alpha_i - \alpha_i^*) \quad (2.16)$$

dengan kendala,

$$\sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0$$

$$0 \leq \alpha_i, \alpha_i^* \leq C, \quad i = 1, 2, 3, \dots, n$$

Berdasarkan persamaan proses deviasi (2.16), variabel utama yang diperoleh adalah α_i dan α_i^* . Penyelesaian masalah berasal dari vektor w kemudian disubstitusikan ke fungsi $f(x)$.

$$w = \sum_{i=1}^m (\alpha_i - \alpha_i^*) x_i \quad (2.17)$$

Nilai b perlu dimaksimalkan dari kondisi tersebut.

$$\alpha_i(\epsilon + \xi_i + y_i - (\mathbf{w} \cdot \mathbf{x}) - b) = 0 \quad (2.18)$$

$$\alpha_i^*(\epsilon + \xi_i^* + y_i - (\mathbf{w} \cdot \mathbf{x}) - b) = 0$$

$$(C - \alpha_i)\xi_i^* = 0$$

$$(C - \alpha_i)\xi_i^* = 0 \quad (2.19)$$

diperoleh,

$$b = y_i - \sum_{i=1}^m (\alpha_i - \alpha_i^*) \cdot (x_i x_j) + \epsilon \quad (2.20)$$

$$b^* = y_i - \sum_{i=1}^m (\alpha_i - \alpha_i^*) \cdot (x_i x_j) - \epsilon \quad (2.21)$$

Berdasarkan persamaan (2.21), $C = \alpha_i$, menyebabkan \mathbf{w} dihitung berdasarkan *support vector*. Mengikuti perhitungan nilai \mathbf{w} dan b serta substitusi persamaan (2.6) dan persamaan (2.16), digunakan fungsi regresi SVR berikut untuk kasus linear:

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \cdot (x_i, x_j) + b \quad (2.22)$$

Dengan perkiraan nilai b

$$b = y_i - \mathbf{w} \cdot \mathbf{x}_i - \epsilon, \quad \text{untuk } 0 \leq \alpha_i \leq C \quad (2.23)$$

$$b^* = y_i - \mathbf{w} \cdot \mathbf{x}_i + \epsilon, \quad \text{untuk } 0 \leq \alpha_i^* \leq C \quad (2.24)$$

Sebaliknya, fungsi nonlinier SVR memberikan pendekatan berbeda dengan mentransfer data x dari wilayah masukan ke wilayah yang lebih kompak melalui fungsi φ sehingga $\varphi: x \rightarrow \varphi(x)$. Oleh karena itu, fungsi *regresi SVR nonlinier* dapat dijelaskan sebagai berikut:

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \varphi(x_i) \cdot \varphi(x) + b \quad (2.25)$$

dimana

- $f(x)$ = fungsi regresi
- $\varphi(x)$ = titik difitur F, hasil pemetaan x pada ruang input
- x = vektor input
- b = bias

Namun kesulitan dalam prosesnya adalah transformasi yang sering terjadi dan sulit dipahami. Campuran ini dapat dianalisis dengan menggunakan kernel, khususnya perkalian skalar $\varphi(x_i) \cdot \varphi(x)$ pada daerah yang lebih cocok dapat dibandingkan dengan fungsi kernel

$$K(x_i, x) = \varphi(x_i) \cdot \varphi(x) \quad (2.26)$$

Dengan fungsi kernel ini, dapat mendefinisikan transformasi φ dengan lebih sederhana. Oleh karena itu, fungsi regresi nonlinier SVR pada persamaan (2.26), dapat

dinyatakan sebagai berikut:

$$f(x) = \sum_{i,j=1}^m (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (2.27)$$

Perbedaan SVM dan SVR adalah jika tujuan SVM adalah mengklasifikasikan dataset menjadi dua zona, maka tujuan SVR adalah menentukan cara mengklasifikasikan dataset kedalam satu zona dengan tetap mempertahankan nilai *epsilon* (ϵ) yang konstan. SVM terbagi menjadi dua, sedangkan SVR memadatkan semua menjadi satu.

Kernel

Fungsi kernel adalah komponen kunci dari metode SVR. Algoritma SVR ditentukan oleh jenis fungsi kernel dan parameter yang digunakan. Metode kernel memindahkan data ke dimensi yang lebih besar, sehingga lebih mudah untuk dianalisis dan disusun. Algoritma dengan fungsi kernel dapat dengan mudah dipindahkan ke ruang yang lebih besar tanpa memerlukan input data yang rumit.

1. Kernel Linear

Kernel linier adalah fungsi kernel paling dasar. Metode berbasis kernel memiliki bias terhadap fungsi linier jika dibandingkan dengan data non-kernel. Garis kernel dapat digunakan sebagai berikut.

$$K(x_i, x_j) = x_i \cdot x_j \quad (2.28)$$

dengan

$K(x_i, x_j)$ = fungsi kernel

x_i = nilai x ke-i

x_j = nilai x ke-j

2. Kernel Polinomial

Polinomial kernel adalah jenis kernel non-stasioner (data yang tidak bervariasi dan memiliki mean yang konsisten dari waktu ke waktu). Kernel polinomial paling baik digunakan untuk masalah ketika semua data pelatihan dinormalisasi. Kernel polinomial dapat diakses menggunakan metode berikut.

$$K(x_i, x_j) = (1 + x_i \cdot x_j)^d \quad (2.29)$$

dengan

$K(x_i, x_j)$ = fungsi kernel

x_i = nilai x ke-i

x_j = nilai x ke-j

d = derajat polinomial

3. Kernel Gaussian RBF

Kernel Gaussian mengacu pada kernel fungsi basis radial. Parameter sigma (σ) dapat disesuaikan berdasarkan kinerja kernel sehingga memerlukan identifikasi berdasarkan hasil yang diinginkan. Proyek eksponensial akan menjadi kurang linier, sedangkan proyek yang lebih besar akan kehilangan sifat nonliniernya. Kernel Gaussian RBF dapat dipilih menggunakan kriteria berikut.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (2.30)$$

dengan

$K(x_i, x_j)$ = fungsi kernel

x_i = nilai x ke-i

x_j = nilai x ke-j

σ = sigma

Hasil dan Pembahasa

1. Pengumpulan Data

Data yang dibutuhkan untuk proses perhitungan adalah data historis harga penjualan beras dari Badan Pangan Nasional di Provinsi Jawa Barat. Data tersebut mencakup informasi tentang tanggal, harga beras premium, dan harga beras medium. Data yang diambil berupa data harga beras premium dan harga beras medium sejak tanggal 1 Maret 2023 sampai 1 Maret 2024 dengan jumlah 367 data. Data di bagi menjadi dua tahap yaitu tahap training dan testing. Pada penelitian kali ini data dibagi dengan partisi 50:50 dimana 50% data training dan 50% data testing dan 60:40, 70:30, 80:20, 90:10 dari data harga beras premium dan harga beras medium.

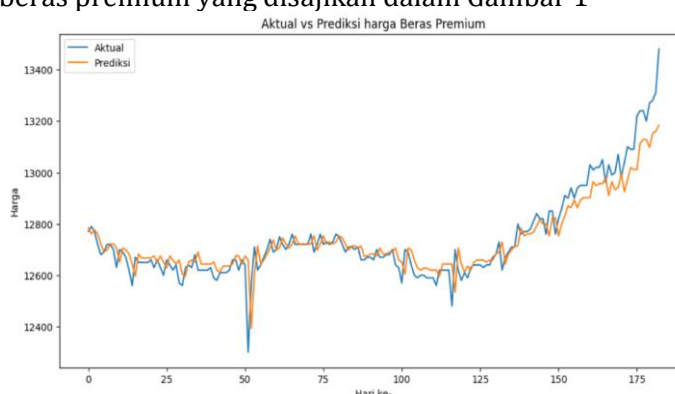
2. Model SVR

Pembentukan model SVR dilakukan dengan menentukan parameter – parameter C , epsilon (ϵ) dan gamma (γ). Parameter C berfungsi sebagai parameter penalti atas kesalahan yang dilakukan model saat menyesuaikan data pelatihan. Nilai C yang lebih tinggi menunjukkan toleransi kesalahan yang lebih rendah dan mungkin menghasilkan model yang lebih akurat. Parameter epsilon (ϵ) digunakan untuk mengontrol toleransi kesalahan pada model. Parameter gamma (γ) digunakan untuk mengontrol pengaruh setiap sampel data yang digunakan untuk membangun model. Hasil proses penentuan parameter menggunakan algoritma SVR ditunjukkan pada Tabel 2.1 di bawah ini.

Tabel 1. Nilai C, Epsilon, dan Gamma

C	(ϵ)	(γ)
10	0.01	0.01

Menggunakan nilai parameter pada tabel 2.1, selanjutnya dilakukan prediksi terhadap harga beras premium yang disajikan dalam Gambar 1



Gambar 1. Prediksi Harga Beras Premium Aktual dan Prediksi

Hasil validasi model SVR menggunakan metrik evaluasi MSE, dan RSME diperoleh:

Tabel 2. Hasil Validasi Model SVR

Mean Squared Error (MSE)	0.00063
Root Mean Squared Error (RSME)	0.02384

Selanjutnya, dilakukan pembagian data dengan perbandingan 60%:40% sebesar 220 data training dan 146 data testing, 70%:30% sebesar 256 data training dan 110 data testing, 80%:20% sebesar 293 data training dan 73 data testing, dan 90%:10% sebesar 330 data training dan 36 data testing yang disajikan pada tabel berikut:

Tabel 3 Hasil Evaluasi Model SVR Beras Premium

Pembagian Data	C	epsilon	gamma	MSE	RMSE
60:40	10	0.01	0.01	0.00063408	0.02384252
70:30	10	0.01	0.01	0.00063408	0.02384252
80:20	10	0.01	0.01	0.00063408	0.02384252
90:10	10	0.01	0.01	0.00063408	0.02384252


Sedangkan untuk beras tipe medium disajikan dalam tabrl berikut:

Tabel 4 Hasil Evaluasi Model SVR Beras Medium

Pembagian Data	C	epsilon	gamma	MSE	RMSE
50:50	10	0.01	0.01	0.00189495	0.03286863
60:40	10	0.01	0.01	0.00095789	0.02762504
70:30	10	0.01	0.01	0.00142356	0.03355852
80:20	10	0.01	0.01	0.00136049	0.03312317
90:20	10	0.01	0.01	0.00128937	0.03257630

Tabel 4 menunjukkan bahwa model SVR dengan parameter yang diberikan tampaknya konsisten dan dapat diandalkan. Nilai Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE) relatif rendah untuk setiap percobaan pembagian data, ini menunjukkan bahwa model SVR mampu memberikan prediksi yang baik untuk beras medium.

Menggunakan algoritma Randoearch dan Gridsearch diperoleh hasil sebagai berikut:



Gambar 4.15 Hasil Prediksi Beras Premium Randomsearch dan Gridsearch

Hasil dari Grid Search menunjukkan bahwa parameter terbaik yang ditemukan adalah: $\{ 'C': 0.1, 'epsilon': 0.01, 'gamma': 1, 'kernel': 'rbf' \}$. Hasil pengukuran performa model dengan parameter ini adalah: MSE: 0.0013369, dan RMSE: 0.0328463. Hasil eveluasi kinerja dari model SVR dengan algoritma random search pada beras medium untuk nilai MSE sebesar 0.00148, dan RMSE sebesar 0.03552, dengan parameter menunjukkan bahwa parameter terbaik yang ditemukan adalah: $\{ 'C': 7.0599, 'epsilon': 0.0470, 'gamma': 0.1101, 'kernel': 'rbf' \}$

Simpulan

Penggunaan metode SVR untuk memprediksi harga beras premium, dan harga beras medium menggunakan algoritma random search dan grid search menghasilkan prediksi dengan baik dan juga hasil prediksi mampu mengikuti pola dari data asli. Nilai MSE dan RSME yang diperoleh dari masing-masing model adalah pada model Support Vector Regression (SVR) pada beras premium diperoleh nilai MSE 0.00063408 dan nilai RMSE sebesar 0.0238425, sedangkan beras medium menghasilkan nilai MSE 0.0013604 dan nilai RMSE sebesar 0.0331231. Sedangkan pada model Support Vector Regression (SVR) dengan algoritma Random search pada beras premium diperoleh nilai MSE sebesar 0.0005954 dan nilai RMSE sebesar 0.0230852, sedangkan pada beras medium diperoleh nilai MSE sebesar 0.0014819 dan nilai RMSE sebesar 0.0355231. Sedangkan pada model Support Vector Regression (SVR) dengan algoritma Grid search pada beras premium diperoleh nilai MSE sebesar 0.0005966 dan nilai RMSE sebesar 0.0231990, sedangkan pada beras medium diperoleh nilai MSE sebesar 0.0013369 dan nilai RMSE sebesar 0.0328463.

Daftar Pustaka

- [1] Ridwan, D.I.,Setianingsih,C.,& Murti,M.A.(2021).Prediksi Penggunaan Energi Listrik Dengan Menggunakan Metode Support Vector Regression.e-Proceeding of Engineering, 8(6),12135-12144
- [2] Kasus Harian, P., Laverda Subiyanto, M., Amanda, Y., Nadhil Fachrian, M., Yazid Busthomi Rohim, A., Chamidah, N., Matematika, D., & Sains dan Teknologi, F. (n.d.). "PERAMALAN KASUS HARIAN MONKEYPOX DUNIA DENGAN PENDEKATAN SUPPORT VECTOR REGRESSION".
- [3] Novi Selviani, Joko Purwadi, (2023), "Support Vector Regression optimization with Particle Swam Optimization algorithm for predicting the gold prices", BAMME, Vol.3 no.2 (2
- [4] Lature, H., (2022). "Implementasi Metode Support Vector Regression (SVR) dalam Prediksi Persediaan Sarang Walet". Bulletin of Information System and Technology.
- [5] Aulia, A., Aprianti, B., Supriyanto, Y., Rozikin, C., (2022). "Prediksi Harga Emas dengan Menggunakan Algoritma Support Vector Regression (SVR) dan Linear Regression (LR). Jurnal Ilmiah Wahana Pendidikan, Vol. 8, No.5, April 2022
- [6] Nur 'Aeni, U., Prasasti, L, A., Kallista, M., (2020). "Prediksi Jumlah Penumpang dan Penambahan Gerbong Kereta Api Menggunakan Metode Support Vector Regression (SVR). e-Proceeding of Engineering : Vol.7, No.2 Agustus 2020
- [7] F. Novianti, N. Ulinnuha, M. Hafiyusholeh, and A. Arianto, "Prediksi Penggunaan Bahan Bakar pada PLTGU menggunakan Metode Support Vector Regression (SVR)," Techno.Com, vol. 21, no. 2, pp. 249–255, 2022, doi: 10.33633/tc.v21i2.5712.
- [8] Raharjo, A, B., Dinanto, Z, Z., Sunaryono, D., Purwitasari, D., (2021). "Prediksi Akumulasi Kasus Terkonfirmasi Covid-19 di Indonesia Menggunakan Support Vector Regression". Techno.COM, Vol. 20, No.3, Agustus 2021: 372-381
- [9] Drucker, C. M., Scheffer, J. S., & Müller, K.-R. (1997). Support vector regression machines. In *Advances in neural information processing systems* (pp. 779-784). MIT Press.
- [10] Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3), 27.
- [11] Nasution, A. H., dan Prasetyawan, Y. 2008,"Perencanaan & Pengendalian Produksi", Edisi Pertama, Graha Ilmu, Yogyakarta.
- [12] Gambhir, E., Jain, R., Gupta, A., & Tomer, U. (2020). Regression Analysis of COVID-19 using Machine Learning Algorithms. 2020 International Conference on Smart Electronics and Communication (ICOSEC), Trichy, India, 2020, pp. 65-71, doi: 10.1109/ICOSEC49089.2020.9215356. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9215356&isnumber=9215228>.

- [13] Adhikari, A., & Roy, P. (2023). A survey of machine learning evaluation metrics. *ACM Computing Surveys (CSUR)*, 56(3), 1-38.
- [14] Conway, D., & White, J. M. (2012). *Machine Learning for Hackers*. (J. Steele, Ed.).
- [15] Hosseini, M., Javaherian, A., & Movahed, B. (2014). Determination of permeability index using Stoneley slowness analysis, NMR models, and formation evaluations: a case study from a gas reservoir, south of Iran. *Journal of Applied Geophysics*, 109, 80–87.
- [16] Yudhawan, D. H., & Purwaningsih, T., (2020). Developing support vector regression model to forecast stock price of mining companies in Indonesia.
- [17] R. H. Kusumodestoni and S. Sarwido, "Komparasi Model Support Vector Machines (Svm) Dan Neural Network Untuk Mengetahui Tingkat Akurasi Prediksi Tertinggi Harga Saham," *J. Inform. Upgris*, vol. 3, no. 1, 2017, doi:10.26877/jiu.v3i1.1536.
- [18] Al-Omari, M., & Al-Omari, A. (2023). A survey of machine learning algorithms for classification problems. *International Journal of Artificial Intelligence Research (IJAIR)*, 11(1), 1-32.
- [19] M. Awad and R. Khanna, *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, no. May 2016. 2015. doi: 10.1007/978-1-4302-5990-9.
- [20] Scholkopf B, dkk. 2002. *Learning With Kernel*. MIT Press.
- [21] Larochelle, H., et al. 2007. An empirical evaluation of deep architectures on problems with many factors of variation. In: *Proceedings of the 24th international conference on Machine learning - ICML '07*. ICML '07. ACM, New York, NY, USA, pp. 473–480. Available at: (<http://portal.acm.org/citation.cfm?Doid=1273496.1273556>).
- [22] Bergstra, J., Bengio, Y., 2012. "Random search for hyper-Parameter optimization". *J. of Machine Learn. Res.* 13, 281–305 , (Available at <http://dl.acm.org/citation.cfm?id=2188385.2188395>).
- [23] LeCun, Y., et al., 1998. Efficient BackProp. In: Orr, G., Müller, K.-R. (Eds.), *Neural Networks: Tricks of the Trade SE - 2*. Lecture Notes in Computer Science. Springer Berlin, Heidelberg, 9–50, (http://link.springer.com/10.1007/3-540-49430-8_2).
- [24] I. M. Parapat and M. T. Furqon, "Penerapan Metode Support Vector Machine (SVM) Pada Klasifikasi Penyimpangan Tumbuh Kembang Anak," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.* , vol. 2, no. 10, pp. 3163–3169, 2018, [Online]. Available: <http://j-ptiik.ub.ac.id>.
- [25] Yazdani-Asrami, M., Taghipour-Gorjikotaie, M., Song, W., Min Zhang, Weijia Yuan., (2020). "Prediction of Nonsinusoidal AC Loss of Superconducting Tapes Using Artificial Intelligence-Based Model". Digital Object Identifier 10.1109/ACCESS.2020.3037685. Available at (https://www.researchgate.net/publication/346425327_Prediction_of_Nonsinusoidal_AC_Loss_of_Superconducting_Tapes_Using_Artificial_Intelligence-Based_Models)
- [26] Chamidah, N., Sahawaly, R., (2021). "Comparison Support Vector Machine and Naive Bayes Methods for Classifying Cyberbullying in Twitter". *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)* Vol. 7, No. 2, ISSN: 2338-3070, DOI: 10.26555/jiteki.v7i2.21175.
- [27] Bergstra, J., Bengio, Y., (2012). "Random Search for Hyper-Parameter Optimization". *Journal of Machine Learning Research* 13 (2012) 281-305. Available at: (<http://dl.acm.org/citation.cfm?id=2188385.2188395>).
- [28] Yasin, H., Prahutama, A., Wahyu Utami, T., (2014). "Prediksi Harga Saham Menggunakan Support Vector Regression dengan Algoritma Grid Search". *Media Statistika*, Vol. 7, No. 1, Juni 2014: 29-35