

IMPLEMENTASI ALGORITMA *SUPPORT VECTOR REGRESSION* DALAM MEMPREDIKSI HASIL PRODUKSI TANAMAN PANGAN PADA KABUPATEN ACEH BARAT DAYA

Siti Rahmah^{1*}, Rivansyah Suhendra², Hayatun Maghfirah³, Sanusi⁴, Isyatur Raziah⁵

^{1,2,3,4} Program Studi Teknologi Informasi, Fakultas Teknik, Universitas Teuku Umar

Email: ¹sitirahmahsitirahmah6@gmail.com*, ²rivansyahsuhendra@utu.ac.id, ³hayatunmaghfirah@utu.ac.id,

⁴sanusi@utu.ac.id, ⁵isyaturraziah@utu.ac.id

INFORMASI ARTIKEL

Sejarah Artikel:
Diterima: 17 Juli 2025
Revisi: 29 Oktober 2025
Diterbitkan: 30 Oktober 2025

Kata Kunci:
Prediksi
Support Vector Regression
Tanaman Pangan
RBF
Grid Search

ABSTRAK

Kabupaten Aceh Barat Daya merupakan salah satu wilayah lumbung pangan utama di Provinsi Aceh. Namun, dalam beberapa tahun terakhir, menunjukkan penurunan hasil produksi yang disebabkan oleh beberapa faktor, seperti luas tanam, luas panen dan provitas. Penelitian ini bertujuan untuk memprediksi hasil produksi tanaman pangan untuk periode berikutnya dengan menimplementasikan algoritma Support Vector regression (SVR) dengan kernel linear, polynominal dan Radial Basis Function (RBF) yang dioptimalkan dengan metode grid search. Hasil evaluasi menunjukkan bahwa kernel linear baik dalam memprediksi tanaman padi dan ubi jalar, kernel polynominal memprediksi produksi kedelai dan ubi kayu dengan sangat optimal, sementara itu kernel rbf menjadi kernel terbaik dalam memprediksi jagung, kacang hijau, dan kacang tanah. Dengan demikian, implementasi SVR, khususnya kernel rbf, terbukti akurat dan efektif dalam memberikan prediksi sehingga dapat dimanfaatkan untuk mendukung perencanaan strategis produksi tanaman pangan daerah tersebut.

*Copyright © 2025 Jurnal Teknologi Informasi UTU
All rights reserved*

1. Pendahuluan

Kabupaten Aceh Barat Daya merupakan salah satu wilayah yang memberikan kontribusi signifikan terhadap produksi tanaman pangan di Provinsi Aceh. Berdasarkan data pada Dinas Pertanian Dan Perkebunan Aceh, dimana pada periode Oktober 2021 – April 2022, Kabupaten Aceh Barat Daya menempati peringkat ke-6 sebagai penyumbang produksi padi terbesar di provinsi tersebut. Pada periode tersebut, total produksi padi mencapai 28.452 ton dengan luas tanam sebesar 7.365 hektare [1].

Meskipun memiliki potensi yang besar, tren produksi tanaman pangan dalam tahun terakhir menunjukkan penurunan. Pada tahun 2024 hasil produksi tanaman pangan di Kabupaten Aceh Barat Daya tercatat sebesar 91.990,73 ton dan mengalami penurunan 18,72 persen dibanding tahun sebelumnya [2]. Penurunan hasil produksi ini disebabkan oleh beberapa faktor diantaranya yaitu faktor luas lahan, luas panen dan provitas. Keberadaan lahan yang cukup dan pengelolaan yang baik sangat penting dalam meningkatkan produksi hasil pertanian [3].

Akan tetapi Tingginya laju alih fungsi lahan sawah berdampak pada menurunnya ketersediaan lahan produktif, yang pada akhirnya mengakibatkan penurunan produksi pangan [4]. Dengan mengadopsi metode dari penelitian Pratista dkk., 2023 yang menunjukkan bahwa Support Vector Regression (SVR) lebih unggul dalam melakukan prediksi dibandingkan algoritma Simple Linear Regression [5]. Dan

penelitian oleh Widiarni dan Mustakim, 2023 memprediksi produksi dan produktivitas kelapa sawit menggunakan algoritma SVR, dan menyimpulkan bahwa kernel RBF merupakan kernel terbaik untuk memperoleh akurasi yang tinggi [6], maka peneliti melakukan pendekatan yang sama untuk memprediksi hasil produksi tanaman pangan di kabupaten aceh barat daya.

Penelitian ini bertujuan untuk memberikan gambaran hasil produksi untuk periode yang akan datang. Sehingga dapat dijadikan acuan dalam melakukan pengambilan keputusan untuk dapat mencapai target produksi tanaman pangan untuk periode berikutnya dan dapat memberikan kontribusi bagi dinas pertanian dan pemerintah daerah dalam menyusun strategi optimal untuk meningkatkan produksi tanaman pangan. Dengan demikian, pasokan pangan, khususnya komoditas padi sebagai bahan pangan pokok, dapat terpenuhi secara merata di berbagai daerah.

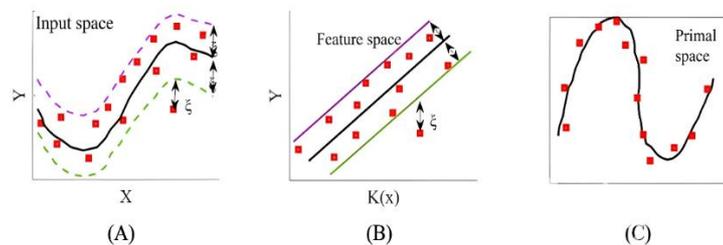
2. Studi Literatur

2.1 Prediksi

prediksi adalah salah satu proses yang secara sistematis atau urut mampu memprediksi dan memperkirakan sesuatu yang mungkin bisa terjadi pada masa depan berdasarkan pada informasi masa lalu. Dalam prediksi tidak selalu memberikan jawaban yang pasti tentang kejadian pada masa mendatang, akan tetapi prediksi berupaya dalam memberikan atau mencari jawaban yang akurat pada kejadian atau fenomena yang mungkin dapat terjadi .

2.2 Algoritma Support Vector Regression

Algoritma Support Vector Regression (SVR) merupakan metode supervised learning yang dikembangkan dari algoritma Support Vector Machine (SVM). Algoritma ini dipelopori pertama kali oleh Vapnik Dan Cortes pada tahun (1995). Konsep dasar dari algoritma SVR adalah melakukan transformasi nonlinier terhadap ruang input ke dalam ruang berdimensi tinggi, kemudian menemukan hubungan linier antara variabel input dan output di ruang tersebut [7]. Berbeda dengan SVM yang berfokus pada pemisahan dua kelas, SVR bertujuan agar seluruh data berada dalam sebuah zona margin yang ditentukan oleh nilai toleransi ϵ , sambil tetap meminimalkan nilai kesalahan tersebut. Adapun ilustrasi konsep algoritma SVR dapat dilihat pada gambar 2.1 berikut [8].



Gambar 1 Ilustrasi Konsep SVR

Pada Gambar 2.1 garis hitam pada gambar A merupakan hyperplane disini SVR mencoba mencari fungsi (garis hitam) yang meminimalkan kesalahan dengan menjaga sebagian besar data berada dalam zona margin (yang berada di antara garis ungu dan hijau). Selanjutnya pada gambar B SVR menggunakan kernel trick untuk memetakan data ke ruang berdimensi tinggi, di mana hubungan antara variabel menjadi lebih mudah dimodelkan secara linier. Setelah itu pada gambar C menunjukkan proses pelatihan di ruang fitur, hasil regresi non-linear dikembalikan ke ruang input asli, menghasilkan prediksi yang akurat. Adapun Pernyataan umum untuk regresi dinyatakan dalam persamaan berikut [9].

$$f(x) = (W \cdot X) + b \tag{1}$$

Untuk memperoleh generalisasi yang baik pada fungsi $f(x)$ maka diperlukan meminimalkan resiko pada W . W adalah vektor bobot, untuk meminimalkan resiko norm W , yang dinyatakan dalam $\|W\|^2 = \langle W, W \rangle$ dimana $\|W\|^2$ merupakan regualisasi yang mampu mengontrol kapasitas fungsi, sehingga di dapatkan penyelesaian masalah optimasi sebagai berikut :

$$\frac{1}{2} \|W\|^2 \tag{2}$$

Pada Persamaan 2 semua titik diasumsikan berada dalam rentang $f(x) \pm \epsilon$. Apabila ada kondisi dimana nilai eror melebihi ambang nilai ϵ yang disebabkan kemungkinan titik-titik keluar dari rentang $f(x) \pm \epsilon$ Apabila ada kondisi dimana nilai eror melebihi ambang nilai ϵ yang disebabkan kemungkinan titik-titik keluar dari rentang $f(x) \pm \epsilon$ maka dalam keadaan seperti ini diperlukan soft margin atau yang dikenal variabel slack ($\xi_i + \xi_i^*$), sehingga persamaanya berubah menjadi:

$$\phi(W, \xi_i, \xi_i^*) = \frac{1}{2} \|W\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3)$$

Dengan syarat

$$y_i - \langle W, X_i \rangle - b \leq \epsilon + \xi_i$$

$$\langle W, X_i \rangle + b - y_i \leq \epsilon + \xi_i^*$$

$$\xi_i + \xi_i^* \geq 0$$

Keterangan :

C : cost (pinalti atas kesalahan pelatihan)

ξ_i, ξ_i^* : variabel *slack*

Pada Gambar 1 transformasi dilakukan dengan pemetaan vector dari *input space* ke *feature space* yang berdimensi tinggi melalui fungsi ϕ , sehingga $\phi : \mathcal{X} \rightarrow \phi(\mathcal{X})$. Sehingga didapatkan persamaan 4 untuk kasus linear

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) (x_i, x_j) + b \quad (4)$$

Sedangkan untuk persamaan SVR untuk kasus nonlinier yaitu dituliskan dalam persamaan (5) berikut.

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \phi(x_i) \phi(x_j) + b \quad (5)$$

Algoritma svr memiliki fungsi kernel untuk memetakan vektor input ke ruang berdimensi lebih tinggi. Adapun fungsi kernel terdiri dari kernel linear, polynominal dan rbf [10].

a. kernel linear

$$K(x_i, x_j) = (x_i, x_j) \quad (6)$$

b. kernel polynominal

$$K(x_i, x_j) = (x_i, x_j + C)^d \quad (7)$$

c. kernel rbf

$$K(x_i, x_j) = \exp(-\gamma (x_i, x_j)^2) \quad (8)$$

2.3 Grid Search

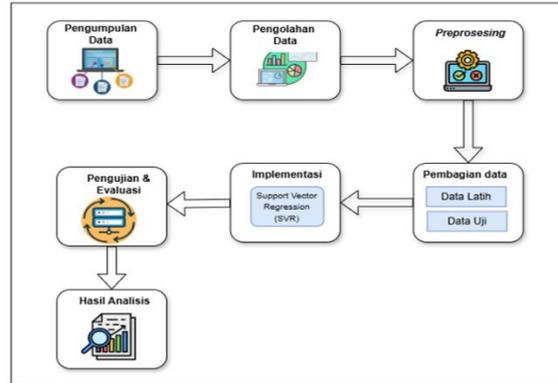
Algoritma Grid search adalah salah satu teknik pencarian parameter yang umum digunakan dalam tahap optimasi parameter model Support Vector Regression (SVR). Tujuan dari penggunaan optimasi ini yaitu untuk menemukan parameter terbaik dalam dataset pelatihan agar model mampu dengan tepat memprediksi data uji. Grid search di dimanfaatkan untuk menemukan kombinasi hyperparameter terbaik, hyperparameter terbaik pada SVR yaitu C dan epsilon. Grid Search bekerja dengan menguji semua kombinasi parameter yang diinginkan, mengevaluasi model untuk setiap kombinasi, dan memilih parameter yang menghasilkan performa terbaik bagi model. Setelah melalui proses pelatihan, kombinasi parameter dengan kesalahan terendah dipilih sebagai hasil optimasi algoritma Grid search [11].

2.4 Tanaman Pangan

Tanaman pangan merupakan jenis tanaman yang mengandung protein yang di dapat menjadi sumber energi dalam tubuh manusia. Taman pangan adalah tumbuhan utama yang di jadikan makanan bagi manusia dan memberikan energi terhadap tubuh manusia. Jenis tanaman pangan ini seperti padi, jagung, kacang-kacangan, dan umbi umbian [12].

3. Metodologi Penelitian

Dalam melakukan penelitian ini, peneliti menggunakan algoritma Support Vector Regression (SVR) Untukmelakukan. Pengumpulan data dilakukan secara pengumpulan primer dan pengumpulan data sekunder. Adapun tahapan pada penelitian ini yaitu:



Gambar 2. Tahapan penelitian

3.1 Pengumpulan Data

Data yang dikumpulkan dalam penelitian ini yaitu sebanyak 378 data tanaman pangan, yang terdiri dari 7 komoditas tanaman pangan yaitu padi, jagung, kedelai, kacang hijau, kacang tanah, ubi kayu dan ubi jalar.

3.2 Pengolahan Data

Pada kajian ini pengolahan data yang dilakukan adalah mengolah data yang berupa hard copy menjadi data excel.

3.3 Preprocessing Data

Tahapan preprocessing ini adalah proses mengolah data yang memiliki format yang masih belum terukur dan terstruktur. Tahapan preprocessing terdiri dari tahapan *cleaning*, *selection* dan *transformation*.

1. Tahapan *Cleaning*, yaitu tahapan pembersihan data untuk mengatasi data yang tidak lengkap, tidak akurat, atau tidak sesuai. Proses ini meliputi penghapusan baris dengan nilai kosong, serta pengubahan nilai kosong dan nilai negatif menjadi nol (0) [13].
2. tahapan *selection*, yaitu pemilihan atribut atau parameter yang sesuai dengan kebutuhan prediksi. Seleksi data dilakukan untuk memisahkan variabel variabel yang mempengaruhi dan variabel yang dipengaruhi.
3. tahapan *Transformation*, yaitu Tahapan transformation saat preprocessing data yang berperan untuk menyesuaikan data. Adapun Teknik transformation pada penelitian ini yaitu teknik normalisasi dengan metode *min-max normalization*. *min-max normalization* yaitu tahapan penskalaan nilai atribut dari suatu data yaitu, antara 0 hingga 1 di setiap fitur. Perhitungan min-max dapat dilihat pada persamaan 9 berikut [11].

$$X_{Scaled} = \frac{(X - X_{min})}{(X_{max} - X_{min})} \quad (9)$$

3.4 Pembagian data

Pembagian data dalam penelitian ini menggunakan pembagian data sebanyak sebanyak 80% data training dan 20 % data testing.

3.5 Pemodeln Algoritma SVR

Dalam melakukan pemodelan algoritma svr maka diperlukan langkah langkah sebagai berikut:

1. Menyiapkan data
2. Melakukan proses normalisasi data.
3. Menentukan kernel, dan melakukan pemilihan turning parameter menggunakan grid search. Adapun parameter dan nilai yang digunakan yaitu pada parameter C dengan nilai (0,01, 0,05, 0,1, 0,5, 1, 10, dan 100) dan nilai ϵ yang digunakan yaitu ((0,01, 0,05, 0,1, 0,5, 1. Selanjutnya degree

dengan nilai 2,3,4 dan gamma (0,01, 0,1, 1). Sedangkan Penentuan fungsi kernel dilakukan dengan percobaan data training dan akan menggunakan tiga kernel yaitu kernel linear, polynominal dan RBF.

4. Menerapkan algoritma SVR untuk mendapatkan hasil analisis.

5. Melakukan pengujian nilai error.

3.5 pengujian performance

Pengujian evaluasi yang digunakan untuk menghitung performance model pada kajian penelitian ini yaitu:

1. Mean Squared Error (MSE)

MSE melakukan pengukuran rata-rata selisih kuadrat antara nilai yang di prediksi oleh model dan nilai sebenarnya. Pengukuran evaluasi menggunakan MSE bertujuan untuk memperkirakan hasil prediksi terhadap data asli. Persamaan mse di tunjukkan pada persamaan 10 berikut .

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{10}$$

2. R-Squared (R Score)

Evaluasi R Score digunakan untuk mengukur seberapa baik model prediksi cocok dengan data sebenarnya. Nilai R Score berkisar diantara 0 sampai dengan 1 dimana, nilai yang paling tinggi menunjukkan keakuratan hasil prediksi. Adapun perhitungannya di tunjukkan pada persamaan 11 berikut [14].

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \tag{11}$$

3. Hasil dan Pembahasan

Penelitian ini telah berhasil memprediksi hasil produksi tanaman pangan di kabupaten aceh barat daya dengan menggunakan metode support vector regression. Adapun hasil pemodelan svr pada tanaman pangan yaitu:

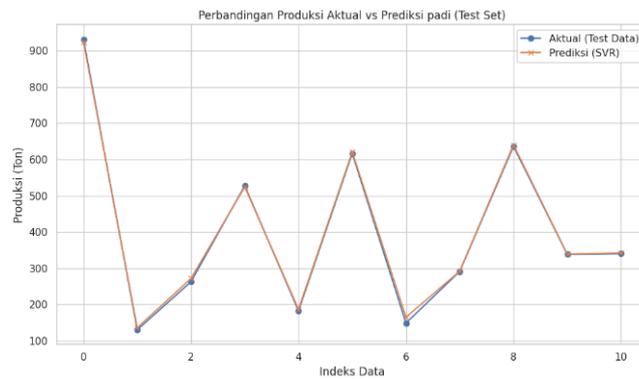
3.1. Hasil Pemodelan SVR data tanaman padi

Hasil prediksi tanaman padi menggunakan pemodelan SVR dengan tiga jenis kernel, didapatkan hasil evaluasi hasil yang bervariasi. Seperti ditunjukkan pada tabel 1. Berikut.

Tabel 1. Hasil Evaluasi Prediksi Padi

Kernel	MSE	R Score
Linear (c=1, ε = 0,01)	0,00015	0,99780
Poly (c=1, ε = 0,01, γ=0,1, d =2)	6,49118	0,99907
RBF c=10, ε = 0,01, γ= 0,1)	5,68411	0,99918

Tabel 1 menunjukkan hasil pemodelan pada kernel linear yang menunjukkan evaluasi MSE sebesar (0,00015) dan R score sebesar (0,99780), yang menunjukkan kesalahan yang sangat minim dan tingkat akurasi tinggi. Kernel polinomial menunjukkan nilai MSE yang besar (6,49118), yang menunjukkan kualitas prediksi yang buruk akan tetapi memiliki akurasi R score yang tinggi (0,99907). Demikian pula, kernel RBF memiliki R score yang tinggi (0,99918) tetapi MSE yang tinggi (5,68411), yang menunjukkan akurasi yang kurang dapat diandalkan meskipun korelasinya kuat. Berdasarkan hasil yang telah diberikan maka kernel linear merupakan kernel yang optimal untuk memprediksi hasil produksi tanaman padi. Gambar 3 menunjukkan visualisasi hasil prediksi menggunakan algoritma SVR.



Gambar 3. Visualisasi Prediksi Padi

Berdasarkan visualisasi grafik pada gambar 3, hasil prediksi produksi tanaman padi. Menunjukkan Keselarasan pola, ini mengindikasikan bahwa model SVR memiliki performa prediktif yang sangat baik, karena nilai hasil prediksi yang dihasilkan relatif mendekati nilai aktual pada data uji.

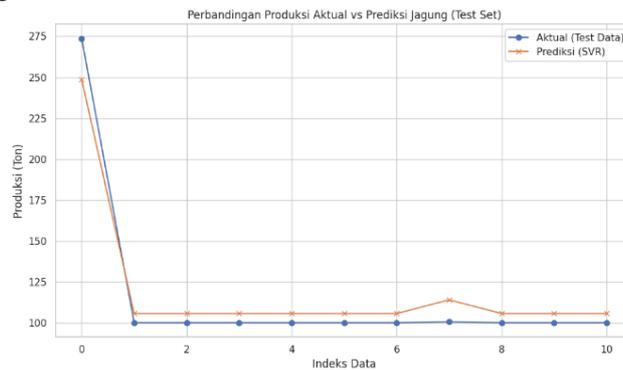
3.2. Hasil pemodelan svr data tanaman jagung.

Hasil prediksi tanaman jagung menggunakan pemodelan SVR dengan tiga jenis kernel, menunjukkan hasil seperti tabel 2 berikut.

Tabel 2. Hasil Evaluasi Prediksi Jagung.

Kernel	MSE	R Score
Linear ($c=100, \epsilon = 0,01$)	0,00014	0,95363
Poly ($c=100, \epsilon = 0,01, \gamma=0,1, d=3$)	2,01319	0,99346
RBF ($c=10, \epsilon = 0,01, \gamma=0,1$)	0,00012	0,95991

Tabel 2 menunjukkan hasil evaluasi kernel linear memberikan hasil prediksi yang cukup baik dengan MSE sebesar (0,00014) dan R score sebesar (0,95363). Kernel polynomial menghasilkan R score tinggi (0,99346), namun disertai MSE yang besar (2,01319), yang menunjukkan kecenderungan overfitting. Sementara itu, kernel RBF memberikan hasil paling optimal dengan MSE terendah (0,00012) dan R score sebesar (0,95991). Berdasarkan evaluasi tersebut, kernel RBF dipilih sebagai model terbaik untuk memprediksi produksi tanaman jagung. Gambar 4 menunjukkan visualisasi hasil prediksi menggunakan algoritma SVR.



Gambar 4. Visualisasi Prediksi Jagung

Visualisasi grafik pada gambar 4 menjelaskan bahwa, garis berwarna oren yang sejajar dan mengikuti pola garis berwarna biru sebagai representasi data aktual. Keselarasan pola ini mengindikasikan bahwa model SVR mampu memprediksi dengan baik, dan menghasilkan nilai prediksi yang relatif mendekati nilai aktual pada data uji.

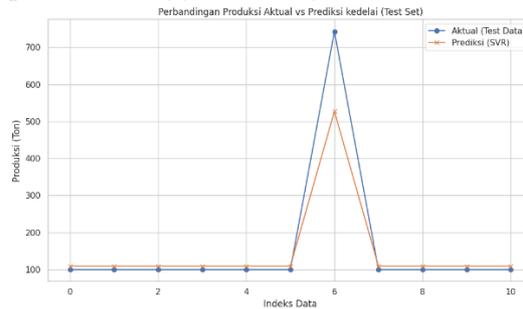
3.3 Hasil pemodelan svr data tanaman Kedelai.

Hasil prediksi tanaman kedelai menggunakan pemodelan SVR dengan tiga jenis kernel, menunjukkan hasil seperti tabel 3 berikut.

Tabel 3. Hasil Evaluasi Prediksi Kedelai.

Kernel	MSE	R Score
Linear ($c=0,5, \epsilon = 0,01$)	0,00661	0,84319
Poly ($c=0,5, \epsilon = 0,01, \gamma=1, d=3$)	0,00524	0,87560
RBF $c=10, \epsilon = 0,01, \gamma=0,1$)	0,00531	0,87398

Hasil prediksi menggunakan pemodelan SVR dengan kernel linear menunjukkan prediksi yang cukup baik, dengan nilai MSE sebesar (0,00661) dan R score sebesar (0,84319). Selanjutnya kernel polynominal menunjukkan hasil dengan nilai MSE sebesar (0,00524) dan R score sebesar (0,87560) yang menunjukkan bahwa kernel ini paling baik dalam memprediksi hasil pada data. Selanjutnya kernel RBF menunjukkan hasil MSE sebesar (0,00531) dan R Score sebesar (0,87398), yang menunjukkan bahwa kernel ini mampu dalam memprediksi data. Berdasarkan hasil yang telah diberikan maka kernel polynominal merupakan kernel yang optimal untuk memprediksi produksi tanaman kedelai. Gambar 5 menunjukkan visualisasi hasil prediksi menggunakan algoritma SVR.



Gambar 5. Visualisasi Prediksi Kedelai.

Visualisasi grafik pada gambar 5, menjelaskan Keselarasan pola yang ditunjukkan oleh garis berwarna oren yang mengikuti pola garis berwarna biru sebagai representasi data aktual. Keselarasan pola ini menunjukkan bahwa model mampu dalam mengenali pola data. Akan tetapi, grafik menunjukkan perbedaan nilai antara nilai prediksi dan nilai sebenarnya.

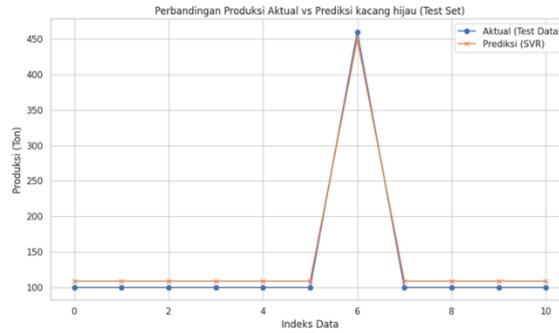
3.3 Hasil Pemodelan Svr Data Tanaman Kacang Hijau.

Hasil prediksi tanaman kacang hijau menggunakan pemodelan SVR dengan tiga jenis kernel, menunjukkan hasil seperti tabel 4 berikut.

Tabel 4. Hasil Evaluasi Prediksi Kacang Hijau.

Kernel	MSE	R Score
Linear ($c=0,5, \epsilon = 0,01$)	1,42525	0,99892
Poly ($c=0,1, \epsilon = 0,01, \gamma=1, d=4$)	0,00097	0,92591
RBF $c=10, \epsilon = 0,01, \gamma=0,01$)	0,00010	0,99236

Hasil prediksi menggunakan pemodelan SVR dengan tiga jenis kernel, menunjukkan hasil evaluasi yang berbeda beda. Kernel linear memberikan nilai MSE sebesar (1,42525) dan R Score sebesar (0,99892) memiliki prediksi kesalahan yang cukup tinggi, meskipun demikian kernel ini memiliki akurasi yang paling tinggi. Selanjutnya kernel polynominal menunjukkan hasil dengan nilai MSE sebesar (0,00097) dan R Score sebesar (0,92591) yang menunjukkan keseimbangan antara tingkat kesalahan dan hasil akurasi. Sementara itu, kernel RBF memberikan nilai MSE sebesar (0,00010) dan R Score sebesar (0,99236), yang menunjukkan kernel mampu meminimalisir kesalahan dan menghasilkan akurasi yang tinggi. Oleh karena itu, kernel RBF merupakan kernel yang paling optimal untuk memprediksi hasil produksi tanaman kacang hijau. Gambar 6 menunjukkan visualisasi hasil prediksi menggunakan algoritma SVR.



Gambar 6. Visualisasi Prediksi Kacang Hijau.

visualisasi grafik pada gambar 6, algoritma support vector regression (SVR) menunjukkan kemampuan sangat baik dalam mengenali pola dan memprediksi nilai pada data. Garis berwarna oren merepresentasikan hasil prediksi yang sejajar dan mengikuti pola garis berwarna biru sebagai representasi data sebenarnya. Hal ini, menunjukkan bahwa model SVR mampu memprediksi hasil produksi tanaman kacang hijau dengan sangat baik.

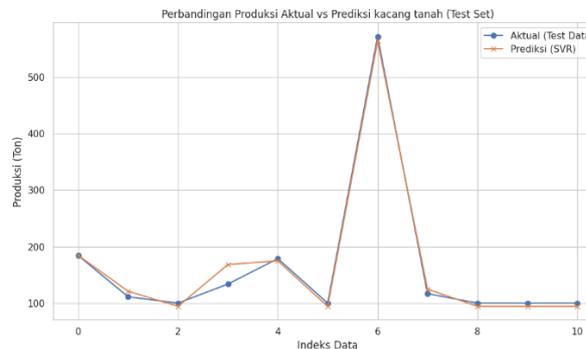
3.3 Hasil Pemodelan Svr Data Tanaman Kacang Tanah.

Hasil prediksi tanaman kacang tanah menggunakan pemodelan SVR dengan tiga jenis kernel, menunjukkan hasil seperti tabel 5 berikut.

Tabel 5. Hasil Evaluasi Prediksi Kacang Tanah.

Kernel	MSE	R Score
Linear ($c=1, \epsilon = 0,01$)	0,00498	0,77087
Poly ($c=100, \epsilon = 0,01, \gamma=0,1, d=4$)	0,00026	0,98793
RBF $c=100, \epsilon = 0,01, \gamma=0,1$)	0,00018	0,99172

Dari Hasil prediksi menggunakan pemodelan SVR menunjukkan hasil evaluasi kernel linear dengan nilai MSE sebesar (0,00498) dan R Score sebesar (0,77087) menunjukkan bahwa kernel ini cukup baik dalam meminimalisir kesalahan dan memberikan hasil akurasi yang cukup baik. Selanjutnya kernel polynominal menunjukkan hasil dengan nilai MSE sebesar (0,00026) dan R Score sebesar (0,98793) yang menunjukkan keseimbangan antara tingkat kesalahan dan hasil akurasi. Sementara itu, kernel RBF memberikan nilai MSE sebesar (0,00018) dan R Score sebesar (0,99172), yang menunjukkan kernel sangat baik dalam meminimalisir kesalahan dan menghasilkan akurasi yang tinggi. Oleh karena itu, kernel RBF merupakan kernel yang paling optimal untuk memprediksi hasil produksi tanaman kacang tanah. Gambar 7 menunjukkan visualisasi hasil prediksi menggunakan algoritma SVR.



Gambar 7. Visualisasi Prediksi Kacang Tanah.

Visualisasi grafik pada gambar 7, menjelaskan bahwa garis berwarna oren mampu mengikuti pola data dengan sangat baik terhadap garis berwarna biru sebagai data sebenarnya. Artinya model ini berhasil memprediksi dengan sangat baik dan meminimalkan tingkat resiko kesalahan yang ditunjukkan dengan Keselarasan pada pola ini menunjukkan bahwa model cukup mampu dalam mengenali pola data

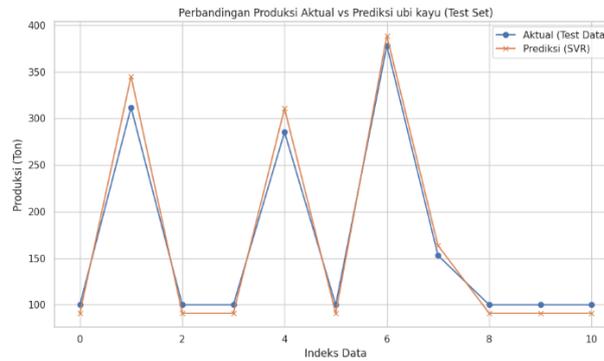
3.3 Hasil Pemodelan Svr Data Tanaman Ubi Kayu.

Hasil prediksi tanaman ubi kayu menggunakan pemodelan SVR dengan tiga jenis kernel, menunjukkan hasil seperti tabel 6 berikut.

Tabel 6. Hasil Evaluasi Prediksi Ubi Kayu.

Kernel	MSE	R Score
Linear ($c=1, \epsilon = 0,01$)	0,00172	0,86192
Poly ($c=10, \epsilon = 0,01, \gamma=1, d=2$)	0,00019	0,98423
RBF $c=100, \epsilon = 0,01, \gamma=0,1$)	0,00028	0,97682

Hasil prediksi menggunakan pemodelan SVR menunjukkan perbedaan evaluasi yang tipis. Kernel linear memberikan nilai MSE sebesar (0,00172) dan R Score sebesar (0,86192) yang menunjukkan kernel ini baik dalam meminimalkan tingkat kesalahan dan akurat dalam memprediksi data. Selanjutnya kernel polynominal memberikan hasil MSE sebesar (0,00019) dan R Score sebesar (0,98423), yang menunjukkan bahwa kernel ini memberikan hasil prediksi dengan sangat baik. Dan kernel RBF memberikan hasil MSE sebesar (0,00028) dan R Score sebesar (0,97682), yang menunjukkan bahwa kernel ini juga sangat baik dalam melakukan prediksi pada data. Akan tetapi, memiliki akurasi yang lebih rendah dibanding kernel polynominal. Dengan demikian, kernel yang paling optimal untuk memprediksi produksi tanaman ubi kayu adalah kernel polynominal. Gambar 8 menunjukkan visualisasi hasil prediksi menggunakan algoritma SVR.



Gambar 8. Visualisasi Prediksi Ubi Kayu.

visualisasi grafik pada gambar 8, menjelaskan garis berwarna oranye sejajar dan mengikuti pola garis berwarna biru sebagai representasi data sebenarnya. Keselarasan pola ini menunjukkan bahwa model sangat baik dalam mengenali pola data dan menghasilkan akurasi prediksi yang mendekati data sebenarnya.

3.3 Hasil Pemodelan Svr Data Tanaman Ubi Jalar.

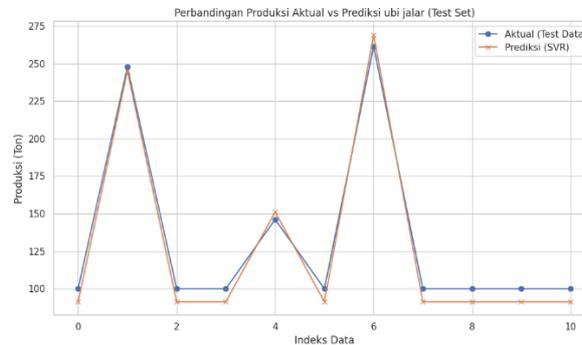
Hasil prediksi tanaman ubi jalar menggunakan pemodelan SVR dengan tiga jenis kernel, menunjukkan hasil seperti tabel 7 berikut.

Tabel 7. Hasil Evaluasi Prediksi Ubi Jalar.

Kernel	MSE	R Score
Linear ($c=0,5, \epsilon = 0,01$)	0,00022	0,97682
Poly ($c=0,5, \epsilon = 0,01, \gamma=1, d=3$)	5,40923	0,97682
RBF $c=100, \epsilon = 0,01, \gamma=0,1$)	7,79317	0,97682

Hasil prediksi menggunakan pemodelan SVR menunjukkan Kernel linear memberikan nilai MSE sebesar (0,00022) dan R Score sebesar (0,97682), menunjukkan bahwa kernel ini mampu melakukan prediksi dengan sangat baik karena, dapat meminimalkan tingkat kesalahan dan memberikan hasil akurasi yang tinggi. Selanjutnya kernel polynominal menunjukkan hasil dengan nilai MSE sebesar (5,40923) dan R Score sebesar (0,97682), yang menunjukkan bahwa kernel ini tidak mampu menangkap kesalahan sehingga menghasilkan kesalahan yang besar akan tetapi kernel dapat

menghasilkan akurasi yang tinggi. Dan kernel RBF menunjukkan hasil MSE sebesar (7,79317) dan R Score sebesar (0,97682), sama seperti kernel polinomial kernel tidak mampu menangkap kesalahan akan tetapi kernel dapat menghasilkan akurasi yang tinggi. Berdasarkan hasil yang telah dijelaskan maka kernel yang paling optimal untuk memprediksi produksi tanaman ubi jalar adalah kernel linear. Gambar 9 menunjukkan visualisasi hasil prediksi menggunakan algoritma SVR.



Gambar 9. Visualisasi Prediksi Ubi Jalar.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, proses analisis prediksi produksi tanaman pangan menggunakan algoritma Support Vector Regression (SVR) menunjukkan bahwa pendekatan ini mampu memodelkan dan memprediksi data produksi dengan akurasi yang bervariasi tergantung pada jenis komoditas dan kernel yang digunakan. Dari hasil evaluasi dapat disimpulkan bahwa, Kernel Linear menunjukkan kinerja dan akurasi yang baik dalam memprediksi hasil produksi padi dengan nilai MSE sebesar (0,00015) dan R score sebesar (0,99780) dan ubi jalar dengan nilai MSE sebesar (0,00022) dan R Score sebesar (0,97682). Dengan nilai kesalahan prediksi yang rendah dan pola yang ditunjukkan oleh grafik mampu mengikuti dan sejajar dengan data sebenarnya. Menunjukkan bahwa kernel ini mampu menghasilkan prediksi yang baik.

Kernel Polynomial menunjukkan kinerja yang optimal dalam memprediksi produksi kedelai dengan nilai MSE sebesar (0,00524) dan R score sebesar (0,87560) dan ubi kayu dengan nilai MSE sebesar (0,00019) dan R Score sebesar (0,98423). Dengan hasil evaluasi yang baik serta keselarasan grafik prediksi yang sejajar dengan data sebenarnya, sehingga menjelaskan kecocokan antara model dan pola data. Kernel RBF menunjukkan kinerja dan akurasi terbaik untuk memprediksi hasil produksi jagung dengan nilai MSE (0,00012) dan R score sebesar (0,95991), kacang hijau dengan nilai MSE sebesar (0,00010) dan R Score sebesar (0,99236) dan kacang tanah dengan nilai MSE sebesar (0,00018) dan R Score sebesar (0,99172). Dengan hasil akurasi tersebut, menjadikan kernel RBF sebagai kernel yang handal untuk menghasilkan prediksi terbaik. Dengan demikian, pemodelan menggunakan algoritma SVR, terutama penggunaan kernel RBF, terbukti efektif dalam memprediksi hasil produksi berbagai jenis tanaman pangan.

Daftar Pustaka

- [1] D. P. dan P. Aceh, "Produksi Padi Aceh Capai 963.004 Ton Periode Januari-Juli 2022, Ini Tiga Wilayah Penyumbang Terbesar." Diakses: 28 Januari 2025. [Daring]. Tersedia pada: <https://distanbun.acehprov.go.id/berita/kategori/berita/produksi-padi-aceh-capai-963004-ton-periode-januari-juli-2022-ini-tiga-wilayah-penyumbang-terbesar-artikel-ini-telah-tayang-di-serambinewscom-dengan-j>
- [2] B. P. M. P. Aceh, "Bsip Aceh Ikut Serta Tanam Padi Serentak Di Aceh Barat Daya." [Daring]. Tersedia pada: <https://aceh.bsip.pertanian.go.id/berita/bsip-aceh-ikut-serta-tanam-padi-serentak-di-aceh-barat-daya>
- [3] N. N. Khasanah dan E. Y. A. Gunanto, "Pengaruh Luas Panen Padi, Produktivitas Lahan, Pertumbuhan harga Beras dan Jumlah Penduduk terhadap Ketersediaan Beras Indonesia Tahun 1990 –2022," vol. 13, no. 2, hal. 67–79, 2024.
- [4] S. E. Nurzannah, M. A. Girsang, dan K. El Ramija, "Faktor-Faktor Yang Mempengaruhi Produksi Padi

- Sawah (*Oryza Sativa L.*) Di Kabupaten Serdang Bedagai,” *J. Pengkaj. dan Pengemb. Teknol. Pertan.*, vol. 23, no. 1, hal. 11–24, 2020.
- [5] S. Pratista, A. Nazir, I. Iskandar, E. Budianita, dan I. Afrianty, “Perbandingan Teknik Prediksi Pemakaian Obat Menggunakan Algoritma Simple Linear Regression dan Support Vector Regression,” *Build. Informatics, Technol. Sci.*, vol. 5, no. 2, 2023, doi: 10.47065/bits.v5i2.4260.
- [6] A. Widiarni dan M. Mustakim, “Penerapan Algoritma Support Vector Regression dalam Memprediksi Produksi dan Produktivitas Kelapa Sawit,” *J. Media Inform. Budidarma*, vol. 7, no. 2, hal. 864, 2023, doi: 10.30865/mib.v7i2.6089.
- [7] A. R. R. Hidayat, O. Parina, dan R. Kurniawan, “Pemanfaatan Data Citra Satelit Untuk Memprediksi Produksi Padi Tahun 2018-2022 dengan Membandingkan Metode Machine Learning dan Ekonometrik,” *Semin. Nas. Off. Stat.*, vol. 2023, no. 1, hal. 225–234, 2023, doi: 10.34123/semnasoffstat.v2023i1.1779.
- [8] Z. Zhang, Q. Zhang, H. Liang, dan B. Gorbani, “Optimizing electric load forecasting with support vector regression/LSTM optimized by flexible Gorilla troops algorithm and neural networks a case study,” *Sci. Rep.*, vol. 14, no. 1, hal. 22092, 2024, doi: 10.1038/s41598-024-73893-9.
- [9] K. N. Suroyo, “Implementasi Metode Svr (Support Vector Regression) Untuk Prediksi Jumlah Positif Covid-19 Di Jawa Timur,” 2022.
- [10] A. A. Mahgfirah, “Analisis Support Vector Regression Dengan Algoritma Grid Search Time Series Cross Validation Untuk Meramalkan Saham Perusahaan Pertambangan Di Indonesia,” vol. 15, no. 1, hal. 37–48, 2024.
- [11] I. M. Gananta, I. N. Purnama, dan K. Q. Fredlina, “Optimasi Prediksi Harga Emas Dengan Metode Support Vector Regression (Svr) Menggunakan Algoritma Grid Search,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 6, hal. 3160–3165, 2024, doi: 10.36040/jati.v7i6.8000.
- [12] I. Nuriati, B. S. Ginting, dan Y. Maulita, “Sistem Pendukung Keputusan Pemilihan Jenis Tanaman Pangan Berdasarkan Kondisi Tanah dengan Metode Moora,” *Semin. Nas. Inform.*, hal. 285–294, 2021.
- [13] R. C. Octavianus, H. Toba, dan B. R. Suteja, “Segmentation and Formation of Customer Regression Model Based on Recency, Frequency and Monetary,” *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 2, hal. 474–484, 2022, doi: 10.28932/jutisi.v8i2.5075.
- [14] Nurahman dan N. Ernawati, “Analisis Algoritma C45 dan Regresi Linear untuk Memprediksi Hasil Panen Kelapa Sawit,” vol. 5, no. 4, hal. 1155–1163, 2024, doi: 10.47065/josyc.v5i4.5828.