

Perbandingan Gaussian Process Regression dan Support Vector Regression dalam Prediksi Suhu Perencanaan Tanam Jagung.

Misranti A. Samulu, Novianita Achmad, dan Siti Nurmardia Abdussamad




Volume 7, Issue 1, Pages 29–34, May 2026

Received 07 April 2026, Revised 07 Mei 2026, Accepted 10 Juli 2026, Published Online 14 Juli 2026

To Cite this Article : M.A. Samulu, N. Achmad, dan S. N. Abdussamad, " Perbandingan Gaussian Process Regression dan Support Vector Regression dalam Prediksi Suhu Perencanaan Tanam Jagung. ", *Jambura J. Probab. Stat.*, vol. 7, no. 1, pp. 29–34, 2026, <https://doi.org/10.34312/jjps.v7i1.38097>


© 2026 by author(s)

JOURNAL INFO • JAMBURA JOURNAL OF PROBABILITY AND STATISTICS



Homepage	: https://ejurnal.ung.ac.id/index.php/jps/index
Journal Abbreviation	: Jambura J. Probab. Stat.
Frequency	: Biannual (May and November)
Publication Language	: English (preferable), Indonesia
DOI	: https://doi.org/10.34312/jjps
Online ISSN	: 2722-7189
Editor-in-Chief	: Ismail Djakaria
Publisher	: Department of Mathematics, Universitas Negeri Gorontalo
Country	: Indonesia
OAI Address	: http://ejurnal.ung.ac.id/index.php/jps/oai
Google Scholar ID	: kWdujzMAAAJ
Email	: redaksi.jjps@ung.ac.id

JAMBURA JOURNAL • FIND OUR OTHER JOURNALS



Jambura Journal of Mathematics



Jambura Journal of Mathematics Education



Jambura Journal of Biomathematics



EULER : Jurnal Ilmiah Matematika, Sains, dan Teknologi

Perbandingan Gaussian Process Regression dan Support Vector Regression dalam Prediksi Suhu Perencanaan Tanam Jagung

Misranti A. Samulu^{1*}, Novianita Achmad², Siti Nurmardia Abdussamad¹

¹ Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Gorontalo

² Program Studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Gorontalo

ARTICLE HISTORY

Received 07 April 2026

Revised 07 Mei 2026

Accepted 10 Juli 2026

Published 14 Juli 2026

KATA KUNCI

GPR, SVR, Prediksi, Suhu, Jagung

KEYWORDS

GPR, SVR, Prediction, Temperature, Corn

ABSTRAK. Jagung merupakan komoditas pangan penting yang berperan dalam sektor pertanian dan perekonomian daerah. Upaya peningkatan produksi jagung di Gorontalo menjadi salah satu program Kementerian Pertanian untuk mendukung ekspor jagung Indonesia. Namun, produktivitas jagung dipengaruhi berbagai faktor, salah satunya suhu akibat perubahan iklim. Penelitian ini bertujuan memprediksi suhu maksimum mingguan sebagai dasar penentuan waktu tanam jagung dengan membandingkan metode Gaussian Process Regression (GPR) menggunakan empat kernel (Periodic, Matern, Radial Basis Function, dan Rational Quadratic) serta metode Support Vector Regression (SVR) yang dioptimasi menggunakan Particle Swarm Optimization (PSO). Data yang digunakan adalah data suhu maksimum mingguan tahun 2023–2024 yang diperoleh dari Stasiun Klimatologi Gorontalo. Hasil penelitian menunjukkan bahwa metode GPR memberikan performa terbaik dengan nilai Mean Absolute Percentage Error sebesar 2,17%, sedangkan SVR-PSO menghasilkan nilai sebesar 2,30%. Berdasarkan hasil peramalan, waktu tanam jagung yang optimal dalam 30 periode ke depan berada pada minggu ke-6 hingga minggu ke-8, karena fase kritis tanaman diperkirakan terjadi pada kondisi suhu yang paling stabil dan berada dalam rentang optimal pertumbuhan jagung.

ABSTRACT. Corn is an important food crop commodity that plays a significant role in the agricultural sector and regional economy. Efforts to increase corn production in Gorontalo have become one of the programs initiated by the Ministry of Agriculture to support Indonesia's corn exports. However, corn productivity is influenced by various factors, one of which is temperature variation resulting from climate change. This study aims to predict weekly maximum temperatures as a basis for determining the optimal planting time for corn by comparing the performance of the Gaussian Process Regression (GPR) method using four kernel functions (Periodic, Matern, Radial Basis Function, and Rational Quadratic) and the Support Vector Regression (SVR) method optimized using Particle Swarm Optimization (PSO). The data used in this study consist of weekly maximum temperature observations from 2023 to 2024 obtained from the Gorontalo Climatology Station. The results indicate that the GPR method achieved the best performance, yielding a Mean Absolute Percentage Error (MAPE) of 2.17%, while the PSO-optimized SVR method produced a MAPE of 2.30%. Based on the forecasting results, the optimal corn planting period within the next 30 weeks is between the sixth and eighth weeks, as the critical growth phase of the crop is expected to occur under the most stable temperature conditions and within the optimal temperature range for corn growth.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. Editorial of JJPS: Department of Statistics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

1. Pendahuluan

Jagung (*Zea mays L.*) merupakan produk unggulan di sektor pertanian yang memiliki peran penting sebagai sumber pangan yang sangat potensial untuk dikembangkan di setiap wilayah. Jagung juga merupakan komoditas pangan utama setelah beras [1]. Jagung yang dihasilkan dari Provinsi Gorontalo adalah jagung kualitas ekspor, sehingga penanaman jagung di Gorontalo mendapatkan perhatian lebih dari pemerintah pusat melalui Kementerian Pertanian [2]. Usaha dalam memaksimalkan peningkatan produksi jagung di Gorontalo menjadi salah satu program oleh Kementerian Pertanian untuk dapat meningkatkan ekspor jagung di Indonesia. Menurut Badan Pusat Statistik 2015, data hasil pro-

duksi jagung mulai tahun 2001 hingga 2015 mengalami fluktuasi [3].

Pemanasan global yang mengakibatkan perubahan iklim diduga menjadi salah satu hal yang menjadi penyebab ketidakpastian tingkat produktivitas tanaman jagung di Indonesia. Dampak perubahan pola iklim ini mulai dirasakan di berbagai wilayah Indonesia, khususnya pada perubahan pola musim kemarau dan musim hujan [1]. Suhu merupakan salah satu faktor yang memiliki korelasi serta pengaruh signifikan terhadap produktivitas jagung. Secara umum, tanaman tropis dapat tumbuh pada kisaran suhu udara antara 15–40°C, sedangkan tanaman jagung memerlukan suhu optimum sekitar 21–28°C untuk pertumbuhan yang baik. Kisaran suhu tersebut berperan penting dalam setiap fase perkembangan tanaman, dengan suhu

*Corresponding Author.

yang ideal untuk berlangsungnya proses fotosintesis berada pada rentang 10–30°C [1].

Perkembangan dan pertumbuhan tanaman sangat ditentukan oleh kondisi iklim, oleh karena itu, akurasi prediksi suhu sangat dibutuhkan sebagai bahan pertimbangan dalam proses perencanaan dan pengambilan keputusan pada sektor tersebut [4]. Penyesuaian pola tanam terhadap pola iklim di masa mendatang merupakan langkah adaptasi yang penting guna menghindari kerugian [5]. Dalam ranah prediksi suhu dan analisis data meteorologi, *machine learning* menjadi pendekatan yang semakin banyak diterapkan karena kemampuannya dalam mengolah data dalam jumlah besar serta mengatasi pola nonlinier yang sulit diselesaikan menggunakan metode konvensional, metode *Gaussian Process Regression* (GPR) dan *Support Vector Regression* (SVR) cocok digunakan pada data iklim seperti suhu karena karakteristik data suhu bersifat nonlinier, fluktuatif, dan memiliki pola musiman [6]. Metode GPR adalah metode populer dalam *machine learning* yang menggunakan pendekatan probabilistik pada analisis *time series*, di mana fungsi ditentukan oleh *mean* dan kovarian [7]. Sedangkan metode SVR dikembangkan dari *Support Vector Machine* (SVM) untuk memecahkan masalah pada analisis regresi dengan mencari fungsi *hyperplane* yang paling sesuai terhadap data dengan *error* yang minimum [8].

Beberapa penelitian terdahulu yang dilakukan oleh [9], yaitu prediksi performa pompa sentrifugal dengan membandingkan GPR, *Least Squares Support Vector Machines* (LS-SVM), dan *Partial Least Squares* (PLS). Hasil penelitian menunjukkan bahwa GPR memiliki kemampuan generalisasi yang lebih baik pada data nonlinier. Selain itu penelitian [7] dalam memprediksi harga saham menggunakan metode GPR dengan menggunakan kernel *Rational Quadratic* dan *Radial Basis Function* (RBF) mendapatkan hasil prediksi dengan nilai rata-rata yang cukup baik. Kemudian penelitian [10] membandingkan performa metode SVR dan *Random Forest* (RF) dalam memprediksi debit aliran sungai (*streamflow*) pada wilayah yang memiliki keterbatasan data di Maroko memberikan hasil bahwa SVR mampu memberikan performa prediksi yang baik dan stabil pada kondisi data terbatas. Penelitian [11] mengenai peramalan intensitas hujan di Jawa Timur pada periode 2017–2023 dengan menggunakan SVR algoritma optimasi parameter *grid search optimization* menghasilkan akurasi prediksi yang moderat. Kemudian penelitian [12] Peramalan harga batubara acuan membandingkan metode *Particle Swarm Optimization* (PSO)-SVR dan *Improved PSO-SVR* memberikan hasil nilai MAPE yang lebih kecil untuk PSO-SVR dibanding IPSO-SVR. Berdasarkan beberapa penelitian tersebut, metode GPR dan SVR mampu memodelkan hubungan linier, bekerja baik pada data historis, serta akurat memberi prediksi probabilistik, dan interperatif. Namun peneliti sebelumnya menyarankan bahwa untuk metode GPR perlu mempertimbangkan kernel yang digunakan untuk peramalan, sehingga simulasi menghasilkan output yang memuaskan [7]. Sedangkan untuk metode SVR diperlukan menggunakan algoritma optimasi parameter (*epsilon*, *gamma*, dan *cost*) seperti PSO dan IPSO [11].

Berdasarkan uraian tersebut, peneliti tertarik untuk membandingkan performa metode GPR dan SVR dengan studi kasus yang berbeda yaitu dalam memprediksi suhu maksimum mingguan. Selain itu pada metode GPR dilakukan perbandingan empat jenis kernel berdasarkan nilai *Root Mean Square Error* (RMSE) terkecil, kemudian dua kernel terbaik akan digabungkan untuk

memperoleh model dengan performa prediksi yang lebih optimal. Kernel yang digunakan yaitu kernel *Periodic*, kernel *Matern*, kernel *Radial Basis Function* (RBF), dan kernel *Rational Quadratic*. Sementara itu, pada metode SVR digunakan optimasi parameter menggunakan algoritma PSO untuk memperoleh parameter optimal berupa *epsilon* (ϵ), *gamma* (γ), dan *cost* (C). Kemudian metode terbaik yang diperoleh akan digunakan untuk melakukan peramalan 30 periode ke depan dan hasil peramalan tersebut digunakan sebagai acuan dalam penentuan waktu penanaman jagung. Penelitian ini bertujuan membandingkan performa metode GPR dengan empat variasi kernel serta metode SVR yang dioptimasi menggunakan algoritma PSO dalam memprediksi suhu maksimum mingguan di Kabupaten Bone Bolango. Dengan demikian, penelitian ini diharapkan tidak hanya memberikan kontribusi dalam peningkatan akurasi prediksi, tetapi juga memberikan manfaat praktis dalam mendukung pengambilan keputusan pada sektor pertanian.

2. Metode Penelitian

Penelitian ini dilakukan secara kuantitatif dengan menggunakan pendekatan peramalan (*forecasting*) membandingkan dua metode *machine learning*, yaitu metode *Gaussian Process Regression* dan metode *Support Vector Regression*. Selain itu, penelitian ini didukung dengan tinjauan pustaka melalui pengumpulan referensi dari jurnal, buku serta referensi ilmiah lainnya. Adapun data yang diolah dalam penelitian ini adalah data suhu maksimum perhari tahun 2023 sampai dengan tahun 2024 yang kemudian dirata-ratakan perminggu, data tersebut diperoleh langsung dari instansi Stasiun Klimatologi Gorontalo. Adapun software yang digunakan adalah bahasa pemrograman Python dengan bantuan platform *Google Colab* dan *Microsoft Excel*. Penelitian ini menggunakan teknik sampling jenuh sebagai metode penarikan sampel dan variabel penelitian merupakan suhu maksimum mingguan.

Berikut diberikan sejumlah tahapan yang diterapkan pada penelitian ini, Secara umu:

1. Proses awal yaitu menginput data suhu maksimum yang telah dirata-ratakan perminggu menggunakan *Microsoft Excel* kedalam *software python google colab*.
2. Selanjutnya melakukan analisis deskriptif untuk mendeskripsikan karakteristik data Suhu Maksimum Mingguan untuk pertimbangan pada analisis model berikutnya.
3. Kemudian tahap *preprocessing* data meliputi pembentukan *window size* sebesar 3, yaitu tiga data suhu maksimum minggu sebelumnya digunakan sebagai input untuk memprediksi satu data berikutnya sehingga membentuk data deret waktu menjadi *supervised learning*. Selanjutnya data dibagi menjadi data pelatihan dan data pengujian dengan perbandingan 80% : 20% secara berurutan agar struktur *time series* tetap terjaga. Setelah itu dilakukan standarisasi data untuk menyeragamkan skala variabel dengan mengubahnya menjadi data yang memiliki rata-rata nol dan standar deviasi satu, sehingga dapat meningkatkan kinerja model pada proses pemodelan.
4. Penerapan metode *Gaussian Process Regression* pada data suhu maksimum mingguan dengan melakukan langkah-langkah berikut:
 - (a) Penentuan *prior Gaussian Process* dan empat fungsi per-

agam (kernel) yang akan digunakan. Pada tahap ini ditentukan distribusi prior *Gaussian Process* beserta empat fungsi peragam (kernel) yang akan digunakan dalam pemodelan yaitu (RBF, *Matern*, *Rational Quadratic* dan *Periodic*). Kernel berfungsi untuk menggambarkan hubungan atau kemiripan antar data input. Empat kernel yang digunakan kemudian dibandingkan untuk mengetahui kernel yang paling mampu merepresentasikan pola data suhu maksimum mingguan.

- (b) Setelah itu melakukan optimasi *hyperparameter* empat fungsi peragam (kernel) yang digunakan. Setiap kernel memiliki *hyperparameter* yang memengaruhi performa model, seperti panjang skala (*length scale*) dan variansi. Oleh karena itu dilakukan optimasi *hyperparameter* untuk memperoleh kombinasi parameter terbaik. Optimasi dilakukan dengan memaksimalkan nilai *log marginal likelihood*, sehingga model dapat menyesuaikan pola data secara optimal.
 - (c) Setelah *hyperparameter* optimal diperoleh, dilakukan pembentukan distribusi *posterior Gaussian Process*. Distribusi *posterior* digunakan untuk menghasilkan prediksi beserta interval ketidakpastiannya. Selanjutnya dilakukan evaluasi terhadap seluruh kernel yang digunakan untuk menentukan dua kernel terbaik berdasarkan nilai kesalahan prediksi terkecil (RMSE).
 - (d) Tahap selanjutnya adalah melakukan prediksi data *testing* menggunakan dua kernel terbaik yang telah digabungkan.
5. Penerapan metode *Support Vector Regression – Particle Swarm Optimization* dengan menggunakan langkah-langkah sebagai berikut:
- (a) Optimasi parameter *Support Vector Regression* (SVR) menggunakan *Particle Swarm Optimization* (PSO): Tahap awal optimasi dilakukan dengan menentukan parameter PSO seperti jumlah iterasi maksimum, jumlah partikel, *inertia weight*, serta parameter percepatan (*cognitive* dan *social coefficient*). Selain itu ditentukan pula rentang parameter SVR yang akan dioptimasi, yaitu parameter C , ϵ , dan γ .
 - (b) Proses optimasi parameter SVR menggunakan PSO. Pada tahap ini setiap partikel merepresentasikan kombinasi parameter SVR tertentu. Partikel bergerak dalam ruang pencarian untuk menemukan kombinasi parameter terbaik berdasarkan nilai fungsi objektif. Proses pembaruan posisi dan kecepatan partikel dilakukan secara iteratif dengan mempertimbangkan pengalaman terbaik individu (P_{best}) dan pengalaman terbaik global (G_{best}).
 - (c) Kemudian menentukan parameter optimal berdasarkan G_{best} pada iterasi konvergen. Proses optimasi dihentikan ketika iterasi mencapai kondisi konvergen atau jumlah iterasi maksimum tercapai. Parameter optimal SVR diperoleh dari nilai *Global Best* (G_{best}) yang menghasilkan kesalahan prediksi minimum.
 - (d) Setelah parameter optimal diperoleh, model SVR dilatih menggunakan data pelatihan. Selanjutnya model digunakan untuk memprediksi data pengujian.

Hasil prediksi dibandingkan dengan data aktual untuk mengevaluasi kemampuan model dalam melakukan peramalan suhu maksimum mingguan.

6. Selanjutnya setelah kedua model dilatih dan diuji, dilakukan evaluasi keakuratan peramalan dengan menghitung nilai MAPE dan menentukan metode terbaik diantara GPR dan SVR-PSO. Tahap evaluasi ini bertujuan untuk mengetahui tingkat ketepatan hasil prediksi yang dihasilkan oleh masing-masing model berdasarkan data pengujian yang digunakan.
7. Setelah mendapatkan metode optimal diantara metode GPR dan SVR, selanjutnya dilakukan proses peramalan terhadap data suhu maksimum mingguan untuk 30 periode ke depan. Hasil peramalan tersebut kemudian digunakan sebagai representasi nilai suhu maksimum mingguan untuk 30 periode yang akan datang.
8. Tahap terakhir yaitu melakukan perencanaan waktu tanam jagung yang tepat yang didasarkan pada hasil peramalan suhu maksimum mingguan pada 30 periode ke depannya.

3. Hasil dan Pembahasan


3.1. Analisis Deskriptif

Analisis deskriptif diterapkan sebelum pengolahan data latih suhu maksimum mingguan untuk memahami karakteristik data. Data yang digunakan merupakan data suhu maksimum harian tahun 2023–2024 yang kemudian diubah menjadi data mingguan melalui proses agregasi. Tujuannya adalah untuk memahami karakteristik data sehingga metode analisis yang diterapkan dapat sesuai dengan sifat data tersebut. Hasil ringkasan dari analisis deskriptif tersebut disajikan pada Tabel 1.

Table 1. Analisis Deskriptif

N	Mean	Min	Maks	Std. Deviasi
104	33,01	29,9	35,7	1,108

Berdasarkan tabel 1, nilai rata-rata (*mean*) suhu maksimum sebesar 33,01°C, yang menunjukkan bahwa secara umum kondisi suhu maksimum berada pada kisaran suhu tinggi yang relatif stabil. Nilai suhu maksimum terendah tercatat sebesar 29,9°C, sedangkan nilai tertinggi mencapai 35,7°C. Rentang nilai tersebut mengindikasikan adanya variasi suhu maksimum yang cukup nyata antar periode pengamatan. Standar deviasi sebesar 1,108°C menggambarkan variasi data terhadap nilai *mean* tergolong sedang. Nilai ini menandakan bahwa fluktuasi suhu maksimum mingguan tidak bersifat ekstrem, namun tetap menunjukkan dinamika perubahan yang konsisten dari waktu ke waktu. Kondisi ini memperkuat dugaan adanya hubungan nonlinier antara waktu dan nilai suhu maksimum, sehingga pendekatan peramalan menggunakan metode *Gaussian Process Regression* (GPR) dan *Support Vector Regression* (SVR) dinilai sesuai untuk memodelkan pola data tersebut. Gambar 1 merupakan plot data suhu maksimum mingguan yang digunakan.



Gambar 1. Visualisasi Suhu Maksimum Mingguan

Berdasarkan gambar 1, data mengalami fluktuasi sepanjang periode pengamatan. Meskipun tidak menunjukkan lonjakan ekstrem, terdapat variasi nilai yang cukup jelas antar minggu. Karakteristik ini menjadi pertimbangan untuk melakukan transformasi skala data pada tahap selanjutnya.

3.2. Preprocessing Data

Pada proses *pre-processing*, data diubah menjadi *supervised learning* menggunakan teknik *sliding window* sebanyak 3 *time step*. Tahap ini dilakukan agar model dapat mempelajari hubungan antar beberapa data sebelumnya dengan data periode berikutnya. Selanjutnya, *dataset* data dibagi menjadi dua *subset* utama, yaitu 80% data pelatihan dan 20% data pengujian. Pembagian dilakukan setelah pembentukan *lag* bertujuan agar pasangan data tetap utuh dan sesuai dengan urutan waktu. Setelah itu dilakukan proses standarisasi dengan parameter *mean* dan simpangan baku yang dihitung hanya dari data pelatihan, hal ini bertujuan untuk menghindari terjadinya *data leakage*, karena kedua metode menggunakan kernel.

3.3. Penerapan metode Gaussian Process Regression

3.3.1. Penentuan Prior Gaussian Process dan Empat Fungsi Peragam (Kernel)

Pada metode *Gaussian Process Regression* (GPR), *prior* ditentukan oleh fungsi *mean* dan fungsi peragam (*kernel*). Dalam penelitian ini, fungsi *mean* ditetapkan sebagai $m(x) = 0$ yang berarti model tidak diasumsikan memiliki kecenderungan tertentu sebelum melihat data. Penentuan *prior* dilakukan bersamaan dengan pemilihan jenis fungsi peragam yang digunakan. Setiap fungsi peragam merepresentasikan asumsi awal yang berbeda terhadap perilaku data suhu maksimum mingguan, sehingga menghasilkan *prior* GPR yang berbeda pula. Empat jenis fungsi peragam digunakan sebagai kandidat *prior*, yaitu kernel *Radial Basis Function* (RBF), kernel *Matérn*, kernel *Rational Quadratic*, dan kernel *Periodic*. Masing-masing kernel diberikan parameter awal yang ditetapkan secara heuristik oleh peneliti dengan mempertimbangkan skala data yang telah distandarisasi serta karakteristik pola musiman yang diamati.

3.3.2. Optimasi Hyperparameter Empat Fungsi Peragam (Kernel)

Proses optimasi *hyperparameter* kernel menggunakan *Log Marginal Likelihood* (LML). Proses LML dihitung berdasarkan matriks kovarians data *training* yang dibentuk oleh *kernel*. Pada setiap iterasi, parameter *kernel* diubah, kemudian matriks kovarians dihitung ulang dan nilai LML dievaluasi. Parameter yang menghasilkan nilai LML maksimum dipilih sebagai *hyperparameter* optimal. Pada penelitian ini proses optimasi *hyperparameter* dilakukan berulang sebanyak 30 kali iterasi dengan menggunakan pustaka *scikit-learn*. Dari seluruh percobaan tersebut, dipilih kombinasi

hyperparameter yang menghasilkan nilai LML terbesar. *Hyperparameter* optimal yang diperoleh pada tahap ini disajikan pada tabel 2

Table 2. Nilai Log Marginal Likelihood Hasil Optimasi Hyperparameter

Kernel	Parameter	LML
RBF	$scale = 0,273$	-108,115
Matérn ($\nu = 0,5$)	$scale = 0,89$	-98,293
Rational Quadratic	$scale = 0,5, \alpha = 0,5$	-110,760
Periodic	$scale = 0,3, Periode = 12$	-142,920

Berdasarkan tabel 2, kernel *Matérn* ($\nu = 0,5$) menghasilkan nilai LML tertinggi dibandingkan kernel lainnya, yaitu sebesar -98,293. Hal ini mengindikasikan bahwa kernel *Matérn* memiliki kemampuan terbaik dalam menyesuaikan pola data suhu maksimum mingguan pada tahap pelatihan. Sementara itu, kernel *Periodic* menghasilkan nilai LML terendah sebesar -142,920 yang menunjukkan bahwa asumsi pola musiman murni kurang sesuai dengan karakteristik data suhu maksimum mingguan pada periode pengamatan.

3.3.3. Pembentukan Posterior dan Penentuan Dua kernel Terbaik

Setelah mendapatkan parameter optimal dari masing-masing *kernel* tahap selanjutnya adalah membentuk *posterior* data uji dari masing-masing *kernel* tersebut. Proses perhitungan *posterior* data uji dilakukan secara otomatis menggunakan *library scikit-learn Gaussian Process Regressor*, *posterior* ini terdiri dari nilai *mean* atau hasil prediksi data *testing* dan standar deviasi. Secara kuantitatif masing-masing *posterior kernel* tersebut dievaluasi menggunakan nilai RMSE pada tabel 3.

Table 3. Nilai RMSE untuk Setiap Kernel GPR


Kernel	RMSE Testing	Peringkat
RBF	1,070	3
Matérn	0,890	1
Rational Quadratic	0,945	2
Periodic	1,090	4

Berdasarkan tabel 3, kernel *Matérn* dan kernel *Rational Quadratic* menghasilkan nilai RMSE *testing* yang memiliki nilai terendah, masing-masing sebesar 0,890 dan 0,945. Sementara itu, kernel RBF dan *Periodic* menunjukkan kesalahan prediksi yang lebih besar. Oleh karena itu, kernel *Matérn* dan *Rational Quadratic* dipilih sebagai dua kernel terbaik yang akan digabungkan dalam satu fungsi peragam gabungan dan dianalisis lebih lanjut pada langkah berikutnya.

3.3.4. Prediksi Data Testing Menggunakan Dua Kernel Terbaik

Kernel gabungan dibentuk dengan menjumlahkan kernel *Matérn* dan kernel *Rational Quadratic* yang masing-masing telah diidentifikasi sebagai dua kernel terbaik berdasarkan RMSE *testing* terendah. Proses optimasi *hyperparameter* untuk kernel gabungan dilakukan secara otomatis pada *scikit-learn* menggunakan algoritma maksimalisasi *Log Marginal Likelihood* (LML) dengan 30 kali

restart optimizer. Setelah kedua kernel terbaik digabung, selanjutnya dilakukan kembali pengujian terhadap data *testing*. Prediksi data *testing* menggunakan dua kernel gabungan ditampilkan pada gambar 2



Gambar 2. Visualisasi Prediksi Data Testing GPR

Kurva prediksi terlihat mengikuti pola data aktual dengan baik, terutama pada tren menurun dan periode stabil. Deviasi yang terjadi bersifat minimal dan tidak mengubah interpretasi pola besar suhu mingguan.

3.4. Penerapan Metode Support Vector Regression □ Particle Swarm Optimization

3.4.1. Optimasi Parameter Support Vector Regression menggunakan Particle Swarm Optimization

Pada proses optimasi parameter *Support Vector Regression* (SVR) menggunakan *Particle Swarm Optimization* (PSO), digunakan 30 partikel dan 30 iterasi serta *inertia weight* ($w = 0,9$) [13], nilai *cognitive coefficient* ($c_1 = 2$), dan nilai *social coefficient* ($c_2 = 2$) [14], sedangkan r_1 dan r_2 merupakan bilangan acak dengan rentang nilai 0 sampai 1. Setiap partikel merepresentasikan kombinasi parameter C , ϵ , dan γ dengan rentang awal nilai masing-masing berdasarkan pengujian rentang pada penelitian terdahulu oleh [15], yaitu nilai $C = 100-500$, $\epsilon = 0,0001-0,1$, dan $\gamma = 1-50$. Pada setiap iterasi, algoritma PSO mengevaluasi seluruh partikel dan menentukan *global best* (*Gbest*) berdasarkan nilai *Mean Absolute Percentage Error* (MAPE) terkecil. Semakin kecil nilai MAPE yang diperoleh, maka semakin optimal kombinasi parameter yang dihasilkan. Tabel 4 menunjukkan nilai *Gbest* pada setiap iterasi beserta nilai MAPE yang dihasilkan selama proses optimasi berlangsung.

Table 4. *Global Best* pada Proses Optimasi PSO


Iterasi	MAPE (%)	C	ϵ	γ
0	2,307	282,716	0,088	13,435
1	2,306	178,225	0,100	12,902
2	2,305	500,000	0,100	13,209
⋮	⋮	⋮	⋮	⋮
30	2,305	259,675	0,100	13,036

Berdasarkan tabel 4, dapat dilihat bahwa nilai MAPE mengalami perubahan pada setiap iterasi hingga mencapai nilai terkecil pada iterasi keempat. Hal ini menunjukkan bahwa algoritma *Particle Swarm Optimization* (PSO) secara bertahap memperbaiki kualitas solusi dengan mencari kombinasi parameter *Support Vector Regression* (SVR) yang menghasilkan kesalahan prediksi yang

semakin kecil. Pada tahap iterasi PSO, hasil perkembangan *Gbest* setiap iterasi mengalami penurunan secara bertahap, hal itu dapat dilihat pada nilai MAPE yang mengalami penurunan secara signifikan dari iterasi 0 hingga mencapai konvergen pada saat iterasi keempat yaitu sebesar 2,304738. Oleh karena itu, parameter pada iterasi konvergen tersebut ditetapkan sebagai *hyperparameter* optimal untuk model SVR.

3.4.2. Pelatihan dan Pengujian Support Vector Regression

Setelah proses optimasi parameter menggunakan algoritma *Particle Swarm Optimization* (PSO) selesai dilakukan, diperoleh kombinasi parameter optimal yang menghasilkan nilai kesalahan prediksi terkecil berdasarkan nilai MAPE. Parameter optimal tersebut terdiri dari parameter $C = 259,675$, $\epsilon = 0,1$ dan $\gamma = 13,03548$ yang digunakan pada fungsi kernel *Radial Basis Function* (RBF). Parameter hasil optimasi PSO selanjutnya digunakan untuk membentuk model akhir SVR. Pada tahap ini, model SVR dilatih secara otomatis menggunakan pustaka *scikit-learn* pada bahasa pemrograman *Python*. Model SVR yang terbentuk kemudian digunakan untuk melakukan prediksi pada data pengujian guna mengetahui kemampuan model dalam memprediksi nilai suhu maksimum mingguan. Model SVR final yang diperoleh dari proses ini selanjutnya digunakan pada tahap evaluasi model untuk menghitung tingkat akurasi prediksi menggunakan ukuran kesalahan atau MAPE. Hasil pengujian SVR dapat dilihat pada grafik hasil peramalan data *testing* dapat dilihat pada gambar 3.



Gambar 3. Visualisasi Prediksi Data Testing SVR-PSO

Berdasarkan gambar 3, perbandingan antara data pengujian aktual dan hasil prediksi menggunakan metode SVR-PSO dapat dilihat dapat merepresentasikan pola data pengujian aktual dengan cukup baik. Meskipun terdapat beberapa perbedaan pada awal periode dan saat terjadi perubahan suhu yang cukup signifikan, secara keseluruhan hasil prediksi menunjukkan kesesuaian yang baik dengan data *testing* aktual. Kondisi ini membuktikan bahwa metode SVR-PSO memiliki kemampuan yang cukup baik dalam memodelkan dan meramalkan suhu maksimum mingguan.

3.5. Evaluasi Keakuratan Peramalan dan Penentuan Metode Terbaik

Setelah metode *Support Vector Regression* (SVR) dan *Gaussian Process Regression* (GPR) diuji menggunakan data *testing* sebanyak 21 observasi, selanjutnya dilakukan evaluasi keakuratan peramalan dengan membandingkan nilai aktual dan nilai prediksi dari masing-masing metode. Evaluasi ini bertujuan untuk mengetahui tingkat kesalahan prediksi pada setiap periode pengujian

dan untuk mengetahui metode manakah yang memiliki performa terbaik dalam meramalkan data suhu untuk perencanaan tanam jagung. Nilai *Absolute Percentage Error* (APE) masing-masing dihitung sebagai perbandingan antara data aktual pengujian dan hasil prediksi untuk menghitung nilai *Mean Absolute Percentage Error* (MAPE). Hasil perhitungan nilai MAPE untuk metode GPR dan SVR pada data *testing* disajikan pada tabel 5.

Table 5. Evaluasi Keakuratan Peramalan Data *Testing*

No	Data Aktual	Prediksi GPR	APE	Prediksi SVR	APE
84	30,7	31,7	3,321	32,9	7,224
85	31,7	32,3	2,066	32,9	4,076
86	31,0	32,2	3,920	33,0	6,511
⋮	⋮	⋮	⋮	⋮	⋮
104	32,4	33,2	2,628	33,1	2,273
Total APE		45,57		48,30	
MAPE (%)		2,17		2,30	

Berdasarkan tabel 5, diperoleh nilai MAPE untuk metode *Gaussian Process Regression* (GPR) sebesar 2,17%, sedangkan metode *Support Vector Regression* (SVR) menghasilkan nilai MAPE yang lebih besar. Nilai MAPE yang rendah mengindikasikan persentase kesalahan peramalan metode GPR lebih kecil dibandingkan metode SVR. Dengan demikian, berdasarkan kriteria evaluasi menggunakan *Mean Absolute Percentage Error* (MAPE), metode GPR dapat dinyatakan sebagai metode terbaik dalam penelitian ini karena memiliki tingkat akurasi peramalan yang lebih tinggi.


3.6. Peramalan Data Suhu Maksimum Menggunakan Metode Optimal

Berdasarkan hasil evaluasi akurasi pada data pengujian, metode *Gaussian Process Regression* (GPR) terpilih sebagai metode terbaik karena memiliki nilai *Mean Absolute Percentage Error* (MAPE) terendah. Oleh karena itu, metode GPR selanjutnya digunakan untuk melakukan prediksi suhu maksimum mingguan selama 30 minggu ke depan. Berbeda dengan metode regresi deterministik, GPR merupakan pendekatan probabilistik yang tidak hanya menghasilkan nilai prediksi (*mean*), tetapi juga memberikan ukuran ketidakpastian (*uncertainty*) dalam bentuk simpangan baku atau interval kepercayaan. Informasi ini penting untuk menggambarkan tingkat keyakinan model terhadap hasil prediksi yang dihasilkan. Hasil prediksi suhu maksimum mingguan selama 30 minggu ke depan menggunakan metode GPR disajikan pada tabel 6 dan ditampilkan pada gambar 4.

Table 6. Hasil Prediksi Suhu Maksimum 30 Minggu ke Depan Menggunakan GPR

Minggu ke-	Mean (°C)	Lower 95% (°C)	Upper 95% (°C)	Standar Deviasi
1	32,753	31,110	34,396	0,838
2	33,454	31,757	35,150	0,865
3	32,674	31,237	34,112	0,733
⋮	⋮	⋮	⋮	⋮
30	31,030	29,166	32,893	0,951

Berdasarkan tabel 6, hasil prediksi suhu maksimum mingguan selama 30 minggu ke depan menggunakan metode *Gaussian Process Regression* (GPR) menunjukkan bahwa suhu maksimum berada pada kisaran 30,5°C hingga 33,4°C. Pada awal periode prediksi, suhu maksimum diperkirakan relatif tinggi dan stabil dengan simpangan baku yang kecil, yang menunjukkan tingkat ketidakpastian model yang rendah. Selanjutnya, pada pertengahan periode prediksi, terjadi kecenderungan penurunan suhu maksimum hingga kisaran 30,6°C–31,9°C disertai peningkatan simpangan baku pada beberapa minggu, yang mengindikasikan meningkatnya ketidakpastian model. Pada akhir periode prediksi, suhu maksimum kembali stabil pada kisaran 30,5°C–31,0°C dengan interval prediksi 95% yang relatif konsisten.



Gambar 4. Visualisasi Prediksi Suhu Maksimum 30 Minggu Ke Depan

Secara umum, hasil peramalan ini mengindikasikan adanya kecenderungan penurunan suhu maksimum secara bertahap dibandingkan awal periode prediksi, dengan tingkat ketidakpastian yang masih dalam batas wajar. Informasi ini dapat dijadikan sebagai acuan dalam perencanaan waktu tanam jagung, terutama dalam menyesuaikan fase pertumbuhan tanaman dengan kondisi suhu yang diperkirakan terjadi selama periode mendatang.

3.7. Perencanaan Waktu Tanam Jagung Berdasarkan Suhu Hasil Prediksi

Perencanaan waktu tanam adalah satu pendekatan esensial untuk memaksimalkan hasil budidaya jagung untuk memaksimalkan pertumbuhan dan hasil produksi. Penentuan waktu tanam dalam penelitian ini dilakukan berdasarkan hasil *forecasting* suhu 30 minggu ke depan dengan mempertimbangkan kebutuhan suhu optimal tanaman jagung pada setiap fase pertumbuhan. Berdasarkan kajian teori jagung tumbuh optimal pada suhu 21–34°C, dengan kisaran suhu ideal pada fase vegetatif dan generatif berada pada rentang 28–32°C. Fase pembungaan yang terjadi sekitar 40–60 hari setelah tanam merupakan fase kritis yang sangat dipengaruhi oleh kondisi suhu lingkungan.

Berdasarkan hasil peramalan yang telah diperoleh, suhu pada minggu ke-1 hingga minggu ke-6 masih berada pada kisaran relatif tinggi, yaitu antara 32°C hingga 33°C. Selanjutnya, mulai minggu ke-7 hingga minggu ke-26 suhu menunjukkan kecenderungan lebih stabil pada kisaran 30–31°C dengan deviasi standar yang relatif kecil. Kondisi ini menunjukkan periode suhu yang lebih mendukung bagi pertumbuhan jagung, khususnya pada fase generatif yang sensitif terhadap stres panas. Setelah minggu ke-26, suhu kembali menunjukkan sedikit peningkatan meskipun masih berada dalam rentang toleransi tanaman.

Dengan mempertimbangkan umur panen jagung rata-rata

90–100 hari (sekitar 13–14 minggu), dilakukan simulasi penentuan waktu tanam untuk memastikan fase pembungaan terjadi pada periode suhu paling optimal. Apabila penanaman dilakukan pada minggu ke-6, maka fase pembungaan diperkirakan terjadi pada minggu ke-12 hingga minggu ke-16. Berdasarkan hasil *forecasting*, suhu pada periode tersebut berada pada kisaran 30–31°C yang termasuk dalam kategori suhu optimal untuk pembentukan tongkol dan pengisian biji. Selain itu, nilai simpangan baku (standar deviasi) yang relatif rendah menunjukkan kondisi suhu yang cukup stabil sehingga risiko stres panas dapat diminimalkan.

Sebaliknya, apabila penanaman dilakukan lebih awal, misalnya pada minggu ke-1, maka fase pembungaan akan terjadi pada saat suhu masih berada di atas 32°C yang berpotensi meningkatkan risiko gangguan pembentukan biji akibat suhu tinggi. Sementara itu, jika penanaman dilakukan terlalu akhir, maka fase generatif berpotensi terjadi saat tren suhu mulai meningkat kembali.

Berdasarkan hasil analisis tersebut, waktu tanam yang direkomendasikan adalah pada minggu ke-6 sampai dengan minggu ke-8. Pada rentang waktu tersebut, fase kritis tanaman diperkirakan terjadi pada periode suhu paling stabil dan berada dalam rentang optimal pertumbuhan jagung. Dengan demikian, perencanaan waktu tanam berbasis hasil *forecasting* suhu ini diharapkan dapat meningkatkan peluang keberhasilan budidaya serta meminimalkan risiko penurunan hasil akibat kondisi suhu yang kurang sesuai.

4. Kesimpulan

Berdasarkan rangkaian analisis yang telah dipaparkan, dapat disimpulkan bahwa penerapan metode *Gaussian Process Regression* (GPR) merupakan metode terbaik dalam prediksi suhu maksimum mingguan dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 2,17%. Sedangkan penerapan metode *Support Vector Regression* (SVR) dalam prediksi suhu maksimum mingguan menghasilkan nilai MAPE sebesar 2,30%. Kemudian hasil peramalan menunjukkan bahwa terjadi kecenderungan penurunan suhu setelah minggu ke-6. Waktu tanam jagung yang tepat dalam 30 periode ke depan adalah pada minggu ke-6 sampai dengan minggu ke-8. Pada minggu tersebut, fase kritis tanaman diperkirakan terjadi pada periode suhu paling stabil dan berada dalam rentang optimal pertumbuhan jagung.

References

- [1] N. Herlina and A. Prasetyorini, "Pengaruh perubahan iklim pada musim tanam dan produktivitas jagung (zea mays l.) di kabupaten malang," *Jurnal Ilmu Pertanian Indonesia*, vol. 25, no. 1, pp. 118–128, 2020.
- [2] W. Noi, E. Adam, and Y. Bakari, "Analisis revealed comparative advantage dan daya saing komoditas jagung di provinsi gorontalo," *Jurnal Triton*, vol. 14, no. 1, pp. 1–9, 2023.
- [3] S. Mamase, "Grnn pemodelan sistem prediksi produktifitas jagung di provinsi gorontalo menggunakan metode grnn," in *SemanTECH (Seminar Nasional Teknologi, Sains dan Humaniora)*, vol. 2, no. 1, 2020, pp. 49–54.
- [4] M. Al Fiani, M. R. Rathomi *et al.*, "Prediksi temperatur maksimum di kota tangjungpinang menggunakan model cnn-lstm," *Komputa: Jurnal Ilmiah Komputer dan Informatika*, vol. 14, no. 1, pp. 129–138, 2025.
- [5] E. Surmaini and A. Faqih, "Kejadian iklim ekstrem dan dampaknya terhadap pertanian tanaman pangan di indonesia," *Jurnal Sumberdaya Lahan*, vol. 10, no. 2, 2016.
- [6] D. Guleryuz, "Estimation of soil temperatures with machine learning algorithms—giresun and bayburt stations in turkey: D. guleryuz," *Theoretical and Applied Climatology*, vol. 147, no. 1, pp. 109–125, 2022.
- [7] E. O. Gultom and M. I. Irawan, "Prediksi harga saham jangka pendek di indonesia menggunakan metode gaussian process regression," *Jurnal Sains dan Seni ITS*, vol. 11, no. 2, pp. A58–A63, 2022.
- [8] R. W. Rahmat, S. Annas, and Z. Rais, "Analisis support vector regression (svr) untuk meramalkan indeks kualitas udara di kota makassar," *VARIANSI: Journal of Statistics and Its application on Teaching and Research*, vol. 5, no. 03, pp. 104–117, 2023.
- [9] A. Sow, I. Traore, T. Diallo, M. Traore, and A. Ba, "Comparison of gaussian process regression, partial least squares, random forest and support vector machines for a near infrared calibration of paracetamol samples," *Results in Chemistry*, vol. 4, p. 100508, 2022.
- [10] B. Bargam, A. Boudhar, C. Kinnard, H. Bouamri, K. Nifa, and A. Chehbouni, "Evaluation of the support vector regression (svr) and the random forest (rf) models accuracy for streamflow prediction under a data-scarce basin in morocco," *Discover Applied Sciences*, vol. 6, no. 6, p. 306, 2024.
- [11] D. Safitri, "Penerapan metode support vector regression (svr) pada prediksi curah hujan di jawa timur," Ph.D. dissertation, Universitas Islam Negeri Maulana Malik Ibrahim, 2024.
- [12] A. Umiyati, D. Dasari, and F. Agustina, "Peramalan harga batubara acuan menggunakan metode psosvr dan ipsosvr," *Jurnal EurekaMatika*, vol. 9, no. 1, pp. 69–94, 2021.
- [13] P. Kumar and L. Kumar, "Optimization of the fuel cost, real and reactive power loss in ieee-57 bus systems using pso," *International journal of economic perspectives*, no. 7, p. 135–148, 2023.
- [14] Z. Chen, Y. Wang, T. H. Chan, X. Li, and S. Zhao, "A particle swarm optimization algorithm with sigmoid increasing inertia weight for structural damage identification," *Applied Sciences*, vol. 12, no. 7, p. 3429, 2022.
- [15] R. Difitria, I. Cholissodin, and I. Indriati, "Penerapan support vector regression dan particle swarm optimization untuk prediksi jumlah kunjungan wisatawan mancanegara ke daerah istimewa yogyakarta," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 4, no. 5, pp. 1364–1371, 2020.