



Optimasi Hyperparameter Untuk Prediksi Nilai Tukar Mata Uang Dollar AS (USD) Dengan Rupiah (IDR) Menggunakan Gaussian Process Regression (GPR) Dengan Rational Quadratic dan Matern Kernel

Richard Petrus Haposan Siagian¹, Ani Dijah Rahadjoe², Muhammad Muharrom Al Haromainy³

^{1,2,3}Universitas Pembangunan Nasional "Veteran" Jawa Timur, Indonesia

E-mail: 21081010250@student.upnjatim.ac.id

Article Info	Abstract
Article History Received: 2025-09-10 Revised: 2025-10-15 Published: 2025-11-11 Keywords: <i>Gaussian Process Regression;</i> <i>Kernel Rational Quadratic;</i> <i>Kernel Matérn;</i> <i>Hyperband Optimization;</i> <i>Prediksi Nilai Tukar;</i> <i>USD/IDR.</i>	Currency exchange rate prediction is one of the important issues in economics because exchange rate fluctuations can affect the stability of trade and investment. This study proposes the application of Gaussian Process Regression (GPR) with Rational Quadratic (RQ) and Matérn kernels optimized using Hyperband to model the movement of the USD exchange rate against the Rupiah (USD/IDR). The data used includes daily exchange rates. The dataset was collected over a period of 5 years from the investing website and BPS. Feature extraction was performed by creating time variables (Year, Month, Day, Day of Week) and Moving Average to capture short-term patterns. The results of the experiment show that the combination of Hyperband with the RQ and Matérn kernels can improve the performance of GPR in terms of prediction accuracy compared to the approach without optimization. Evaluation using the MAE, RMSE, MAPE, and R^2 metrics confirms that both kernels are effective in reducing prediction errors and improving model stability. Thus, this approach can be a reliable alternative for foreign exchange rate analysis and forecasting.

Artikel Info	Abstrak
Sejarah Artikel Diterima: 2025-09-10 Direvisi: 2025-10-16 Dipublikasi: 2025-11-11 Kata kunci: <i>Gaussian Process Regression;</i> <i>Kernel Rational Quadratic;</i> <i>Kernel Matérn;</i> <i>Hyperband Optimization;</i> <i>Prediksi Nilai Tukar;</i> <i>USD/IDR.</i>	Prediksi nilai tukar mata uang merupakan salah satu permasalahan penting dalam bidang ekonomi karena fluktuasi kurs dapat memengaruhi stabilitas perdagangan dan investasi. Penelitian ini mengusulkan penerapan Gaussian Process Regression (GPR) dengan kernel Rational Quadratic (RQ) dan Matérn yang dioptimasi menggunakan Hyperband untuk memodelkan pergerakan kurs USD terhadap Rupiah (USD/IDR). Data yang digunakan meliputi nilai tukar harian Dataset diambil selama 5 tahun dari website investing dan BPS. Proses ekstraksi fitur dilakukan melalui pembentukan variabel waktu (Year, Month, Day, Day of Week) dan Moving Average untuk menangkap pola jangka pendek. Hasil eksperimen menunjukkan bahwa kombinasi Hyperband dengan kernel RQ dan Matérn mampu meningkatkan performa GPR dalam hal akurasi prediksi dibandingkan dengan pendekatan tanpa optimasi. Evaluasi menggunakan metrik MAE, RMSE, MAPE, dan R^2 mengonfirmasi bahwa kedua kernel tersebut efektif dalam mengurangi error prediksi dan meningkatkan kestabilan model. Dengan demikian, pendekatan ini dapat menjadi alternatif yang andal untuk analisis dan peramalan kurs valuta asing.

I. PENDAHULUAN

Nilai tukar mata uang merupakan salah satu indikator penting dalam perekonomian suatu negara karena memengaruhi stabilitas perdagangan internasional, arus investasi, serta daya saing ekspor. Pergerakan kurs yang fluktuatif sering kali dipengaruhi oleh berbagai faktor internal maupun eksternal, seperti inflasi, harga komoditas global, suku bunga, dan kinerja ekspor. (Abisa and Munir, 2024) Oleh karena itu, metode prediksi nilai tukar yang akurat sangat dibutuhkan untuk membantu pengambilan keputusan dalam bidang ekonomi, bisnis, maupun kebijakan moneter.

Berbagai pendekatan telah digunakan dalam memprediksi nilai tukar, mulai dari model statistik tradisional hingga metode berbasis machine learning. Model parametrik seperti

ARIMA banyak digunakan karena kesederhanaannya, namun sering kali kurang mampu menangkap pola non-linear pada data keuangan yang kompleks. Di sisi lain, model berbasis jaringan saraf tiruan (neural network) menawarkan fleksibilitas yang tinggi, tetapi cenderung membutuhkan data yang sangat besar, waktu komputasi yang panjang, serta rentan terhadap overfitting. (Yadav et al., 2024)

Sebagai alternatif, Gaussian Process Regression (GPR) muncul sebagai pendekatan non-parametrik yang mampu memodelkan hubungan non-linear dengan fleksibel tanpa memerlukan asumsi bentuk fungsi tertentu. Salah satu model yang relevan dalam konteks ini adalah Gaussian Process Regression (GPR), yang memiliki kemampuan probabilistik dan fleksibel dalam membangun prediksi berbasis Kernel

Keunggulan GPR terletak pada kemampuannya memberikan estimasi prediksi sekaligus tingkat ketidakpastian (uncertainty estimation), sehingga lebih informatif dibandingkan model regresi konvensional (Suphawan, Kardkasem and Chaisee, 2022). Kinerja GPR sangat bergantung pada pemilihan kernel, di mana Rational Quadratic (RQ) dan Matérn menjadi dua kernel yang banyak digunakan untuk menangkap dinamika data dengan karakteristik fluktuatif.

Namun demikian, penentuan parameter kernel pada GPR merupakan tantangan tersendiri karena sangat memengaruhi kualitas prediksi (Akbari et al., 2023). Untuk mengatasi hal ini, penelitian ini mengadopsi metode optimasi Hyperband, yang terbukti efisien dalam melakukan pencarian hyperparameter secara adaptif dengan memanfaatkan sumber daya komputasi secara lebih efektif dibandingkan metode tradisional (Iversen, 2020).

Berdasarkan latar belakang tersebut, penelitian ini difokuskan pada penerapan GPR dengan kernel Rational Quadratic (RQ) dan Matérn yang dioptimasi menggunakan Hyperband untuk memprediksi nilai tukar USD terhadap Rupiah (USD/IDR). Selain menggunakan data nilai tukar harian, penelitian ini juga memasukkan faktor-faktor eksternal, seperti inflasi, harga emas, dan ekspor, guna meningkatkan akurasi model. Gaussian Process Regression (GPR) adalah metode statistik non-parametrik yang digunakan untuk regresi dan prediksi, yang bekerja berdasarkan prinsip probabilistik. Dalam GPR, fungsi regresi yang mendasari data tidak didefinisikan secara eksplisit, melainkan dianggap sebagai sampel dari proses Gaussian (Gaussian Process), yang merupakan distribusi atas fungsi. Artinya, GPR tidak hanya memberikan prediksi nilai titik (point estimate), tetapi juga menyertakan estimasi ketidakpastian (uncertainty) berupa varians prediksi (Mirshekari et al., 2024).

Dalam Gaussian Process Regression (GPR), distribusi prior untuk data pelatihan ditentukan dengan mengasumsikan bahwa fungsi regresi $f(x)$ tidak dirumuskan secara eksplisit, melainkan dianggap sebagai sampel dari suatu proses Gaussian. Proses ini dicirikan oleh sebuah fungsi mean $m(x)$ dan fungsi kovarians (Kernel) $k(x, x')$. Untuk menyederhanakan perhitungan, fungsi mean umumnya diasumsikan bernilai nol. Keunggulan utama GPR terletak pada kemampuannya untuk memodelkan ketidakpastian. Alih-alih hanya menghasilkan prediksi titik, GPR memberikan distribusi probabilistik atas setiap prediksi, yang mencakup estimasi nilai serta

variannya. Hal ini memungkinkan model tidak hanya memperkirakan nilai keluaran, tetapi juga menyampaikan tingkat kepercayaan atau interval prediksi untuk setiap output. Dengan demikian, GPR menjadi metode yang sangat berguna dalam konteks data yang mengandung ketidakpastian atau Noise. Dalam konteks regresi nonparametrik Bayesian, GPR memungkinkan penempatan prior Gaussian secara langsung pada fungsi regresi $f(x)$, sehingga fleksibel dalam menangkap pola kompleks pada data (Jarwadi et al., n.d.).

Dalam Gaussian Process Regression (GPR), distribusi prior untuk data pelatihan ditetapkan dengan asumsi bahwa fungsi regresi $f(x)$ tidak dinyatakan secara eksplisit, melainkan dianggap sebagai sampel dari suatu proses Gaussian. Proses ini dicirikan oleh dua komponen utama, yaitu fungsi mean dan fungsi kovarians atau Kernel. Untuk menyederhanakan perhitungan, fungsi mean umumnya diasumsikan bernilai nol. GPR dirancang untuk mempertimbangkan ketidakpastian dalam proses prediksi, sehingga tidak hanya menghasilkan nilai prediksi titik, tetapi juga menyediakan distribusi probabilistik yang menggambarkan seberapa yakin model terhadap hasil prediksinya (Wang, 2023).

Kernel Rational Quadratic (RQ) adalah salah satu Kernel yang digunakan dalam metode Gaussian Process Regression (GPR) untuk memodelkan hubungan nonlinier antara fitur dan target. Kernel ini merupakan generalisasi dari Kernel Radial Basis Function (RBF), tetapi memiliki kemampuan tambahan dalam menangani variasi skala (scale variation) antar data.

Secara intuitif, Kernel Rational Quadratic dapat dianggap sebagai jumlah tak hingga Kernel RBF dengan panjang skala yang bervariasi. Artinya, Kernel ini sangat baik digunakan untuk data yang menunjukkan heteroskedastisitas, yaitu kondisi di mana tingkat fluktuasi atau variasi dalam data tidak konstan sepanjang waktu. Hal ini sangat relevan dalam data ekonomi dan keuangan, seperti nilai tukar mata uang yang sering mengalami perubahan pola dalam jangka pendek maupun panjang. Keunggulan utama dari Kernel ini adalah kemampuannya untuk menyesuaikan diri dengan dinamika data yang berubah-ubah, tanpa perlu menggunakan Kernel yang berbeda secara terpisah. Parameter α memungkinkan Kernel ini untuk merepresentasikan berbagai skala perubahan secara fleksibel: nilai α kecil akan menghasilkan model yang lebih

"kasar", sedangkan nilai α besar mendekati Kernel RBF (halus) (Shi et al., 2022).

Kernel Matern adalah salah satu fungsi Kernel yang digunakan dalam Gaussian Process Regression (GPR) untuk mengukur kemiripan (similarity) antara dua titik dalam ruang fitur. Kernel ini menawarkan fleksibilitas tinggi dalam mengontrol tingkat kekasaran (roughness) fungsi yang diestimasi, yang sangat penting dalam konteks data deret waktu atau data dengan fluktuasi yang tidak selalu halus (Shao and Kumral, 2024).

Dalam konteks prediksi nilai tukar atau data ekonomi yang sering kali bersifat fluktuatif dan tidak linier, Kernel Matern memberikan kemampuan untuk merepresentasikan proses yang tidak terlalu halus, namun tetap memiliki korelasi antar titik yang kuat. Hal ini menjadikannya cocok untuk digunakan dalam Gaussian Process Regression terhadap data seperti nilai tukar USD terhadap IDR (Xu et al., 2021).

Hyperband adalah algoritma optimasi hyperparameter yang dikembangkan untuk mengatasi keterbatasan dari metode pencarian konvensional seperti Grid Search dan Random Search, dengan mempercepat proses pencarian kombinasi hyperparameter terbaik. Hyperband sebagai algoritma resource-aware yang secara efisien mengalokasikan sumber daya (misalnya waktu pelatihan atau jumlah iterasi) hanya kepada konfigurasi yang menjanjikan, sambil mengeliminasi konfigurasi yang buruk sejak awal (Sachdeva and Kumar, 2021).

Dengan menggunakan *Hyperband*, proses tuning menjadi lebih cepat dan hasil prediksi model dapat ditingkatkan secara signifikan. Gaussian Process Regression (GPR) merupakan gabungan dari dua fungsi Kernel, yaitu Radial Basis Function (RBF) dan WhiteKernel, yang masing-masing memiliki peran penting dalam membentuk karakteristik model. Dalam hal ini, ℓ merupakan parameter length scale dari RBF Kernel, yang menentukan seberapa jauh pengaruh suatu titik data terhadap titik lainnya dalam ruang input. RBF Kernel dikenal sebagai Kernel non-linier yang mampu memodelkan hubungan yang kompleks dan halus antar data. Sementara itu, adalah varians Noise dari WhiteKernel, yang secara eksplisit digunakan untuk memodelkan Noise acak atau kesalahan pengamatan dalam data (Li et al., 2018).

Nilai tukar mata uang (exchange rate) adalah harga satu mata uang yang dinyatakan dalam mata uang lainnya. Nilai tukar mencerminkan kekuatan relatif antara dua mata uang dan

digunakan sebagai dasar dalam transaksi internasional, termasuk perdagangan barang dan jasa, investasi lintas negara, dan pengiriman remitansi. Misalnya, nilai tukar USD/IDR menunjukkan berapa banyak rupiah yang dibutuhkan untuk memperoleh satu dolar Amerika Serikat (Triyono, 2008).

II. METODE PENELITIAN



Gambar 1. Alur Penelitian

Metodologi penelitian ini terdiri dari beberapa tahapan utama yang tersusun secara sistematis untuk menghasilkan model prediksi nilai tukar mata uang yang akurat dan stabil. Proses dimulai dari tahap pengambilan dataset, di mana data nilai tukar mata uang USD terhadap Rupiah (IDR) dikumpulkan dari situs keuangan terpercaya seperti Investing.com dalam bentuk data historis harian selama periode tertentu, yaitu sepanjang 5 tahun terakhir berdasarkan hasil justifikasi ilmiah dari studi kalibrasi. Data ini mencakup nilai tukar harian yang akan dijadikan sebagai target prediksi. Tahap berikutnya adalah data preprocessing, di mana data mentah dibersihkan dan disiapkan agar dapat diproses oleh model Machine Learning. Pada tahap ini, dilakukan pengecekan terhadap nilai hilang (missing values), transformasi waktu menjadi format yang sesuai, serta pembentukan fitur seperti moving average, lag features, dan normalisasi menggunakan Min-Max Scaler untuk menjaga skala nilai antar fitur tetap konsisten. Setelah proses pembersihan data selesai.

III. HASIL DAN PEMBAHASAN

A. Hasil Penelitian

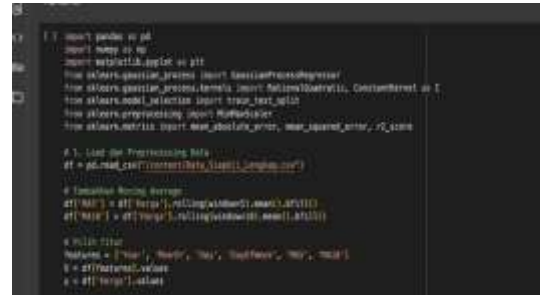
1. Hasil Data Preprocessing

Tabel 1. Data Mentah

tanggal	Harga	Year	Month	Day	Day Of Week	MA5	MA10	Harga_Scaled
07/09/21	14210.0	2021	9	7	1	14248.0	14309.8	0.049
08/09/21	14250.0	2021	9	8	2	14242.0	14295.3	0.064
09/09/21	14250.0	2021	9	9	3	14238.0	14278.8	0.0642
13/09/21	14250.0	2021	9	13	0	14232.0	14245.5	0.0642
14/09/21	14245.0	2021	9	14	1	14239.0	14243.5	0.434
15/09/21	14240.0	2021	9	15	2	14237.0	14239.5	0.0607

Dalam penelitian ini, proses akuisisi data dimulai dengan mengumpulkan data nilai tukar harian USD/IDR dari sumber resmi yang kemudian diperkaya dengan penambahan fitur waktu serta indikator statistik. Tahap awal preprocessing dilakukan dengan memastikan konsistensi format data, khususnya pada kolom tanggal yang diubah menjadi tipe datetime agar mudah diproses lebih lanjut. Selanjutnya, dilakukan ekstraksi fitur waktu yang mencakup tahun (*Year*), bulan (*Month*), hari (*Day*), dan hari dalam minggu (*DayOfWeek*) untuk menangkap pola musiman maupun siklus tertentu dalam pergerakan nilai tukar. Selain itu, ditambahkan fitur teknis berupa *Moving Average* (MA) dengan jendela 5 hari (*MA5*) dan 10 hari (*MA10*) yang berfungsi untuk menghaluskan fluktuasi jangka pendek serta memberikan gambaran tren pergerakan harga. Setelah itu, nilai harga (*Harga*) dinormalisasi menggunakan metode *Min-Max Scaler* sehingga dihasilkan variabel *Harga_Scaled* yang berada pada rentang [0,1] untuk meningkatkan stabilitas perhitungan dalam model pembelajaran mesin. Melalui tahapan akuisisi dan preprocessing ini, data akhir yang siap dilatih tersusun dalam bentuk tabel terstruktur dengan kolom *Tanggal*, *Harga*, fitur waktu, indikator teknis (*MA5* dan *MA10*), serta nilai terstandarisasi (*Harga_Scaled*), sehingga memberikan fondasi yang bersih dan representatif untuk tahap pemodelan selanjutnya.

2. Uji Coba Model



Gambar 2. Pengujian Model

Pada tahap uji model, data dibagi menjadi dua bagian yaitu data latih sebesar 80% dan data uji sebesar 20% tanpa proses shuffle, mengingat karakteristik data bersifat deret waktu sehingga urutan kronologis harus tetap dipertahankan. Model yang digunakan adalah Gaussian Process Regression (GPR) dengan dua jenis kernel, yaitu Rational Quadratic dan Matern. Pengujian dilakukan dalam dua skenario, yakni tanpa optimasi parameter (default) dan dengan optimasi menggunakan algoritma Hyperband untuk memperoleh kombinasi parameter terbaik. Evaluasi performa model dilakukan menggunakan empat metrik, yaitu Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), dan koefisien determinasi (R^2). MAE digunakan untuk menilai rata-rata selisih absolut antara hasil prediksi dan nilai aktual, sementara RMSE lebih sensitif terhadap kesalahan besar sehingga memberikan gambaran akurasi yang lebih ketat. MAPE digunakan untuk mengekspresikan kesalahan dalam bentuk persentase, sehingga memudahkan interpretasi, dan R^2 digunakan untuk melihat sejauh mana model mampu menjelaskan variasi pada data. Hasil pengujian ditampilkan dalam bentuk tabel perbandingan nilai metrik untuk masing-masing kernel, serta grafik Actual vs Predicted pada data uji. Analisis lebih lanjut dilakukan dengan membandingkan performa antar kernel dan menilai pengaruh optimasi Hyperband terhadap peningkatan akurasi model.

3. Uji Kernel Rational Quadratic tanpa Optimasi

Berikut adalah bagian uji coba untuk kernel Rational Quadratic (RQ) yang dilakukan tanpa optimasi dengan target variable nilai tukar



```
Evaluation Metrics for RQ Kernel (Tanpa Optimasi):
MAE : 156.8744
RMSE : 188.0736
MAPE : 0.9621
R2 : 0.7401
```

Gambar 3. Hasil Metriks Evaluasi RQ Kernel tanpa Optimasi

Berdasarkan hasil pengujian menggunakan Rational Quadratic (RQ) kernel tanpa optimasi, diperoleh nilai MAE sebesar 156.87, RMSE sebesar 188.07, MAPE sebesar 0.96%, dan R^2 sebesar 0.74. Nilai MAE dan RMSE menunjukkan bahwa rata-rata kesalahan prediksi model berada pada kisaran 150–180 poin dari nilai aktual kurs USD-IDR, yang relatif masih dapat diterima mengingat volatilitas data keuangan. MAPE yang rendah, yaitu kurang dari 1%, memperlihatkan bahwa kesalahan relatif model terhadap nilai aktual sangat kecil, sehingga prediksi dapat dikatakan cukup presisi. Sementara itu, nilai R^2 sebesar 0.74 menandakan bahwa model mampu menjelaskan sekitar 74% variasi dalam data, meskipun masih ada 26% variasi yang tidak dapat dijelaskan oleh model. Hal ini mengindikasikan bahwa performa model sudah baik, tetapi masih terdapat ruang perbaikan, misalnya melalui optimasi parameter kernel.

Gambar 4. Hasil Visualisasi RQ Kernel
Tanpa Optimasi

Grafik *Actual* vs *Predicted* memperlihatkan perbandingan antara nilai aktual kurs USD-IDR (garis biru) dengan hasil prediksi model (garis oranye putus-putus) pada periode data uji. Secara umum, pola pergerakan garis prediksi mengikuti tren garis aktual, baik pada saat terjadi kenaikan maupun penurunan nilai tukar. Namun, terlihat bahwa garis prediksi cenderung lebih halus dan sering kali berada sedikit di bawah nilai aktual, terutama pada puncak kenaikan atau penurunan yang tajam. Hal ini mengindikasikan bahwa model dengan RQ kernel tanpa optimasi mampu menangkap tren umum pergerakan kurs, tetapi kurang responsif terhadap fluktuasi ekstrem. Dengan kata lain, model cenderung menghasilkan prediksi yang lebih konservatif. Visualisasi ini mendukung hasil metrik evaluasi yang menunjukkan akurasi cukup baik, meskipun terdapat keterbatasan dalam menangkap perubahan nilai tukar yang sangat dinamis.

4. Uji Coba Matern Kernel Tanp Optimasi


Berikut adalah bagian uji coba untuk kernel Matern yang dilakukan tanpa optimasi dengan target variable nilai tukar

```
Evaluation Metrics for Matern Kernel (Tanpa Optimasi):  
MAE : 85.6450  
RMSE : 108.7028  
MAPE : 0.5298  
R2 : 0.9132
```

Gambar 5. Hasil Metriks evaluasi Matern
Kernel Tanpa Optimasi

Pengujian model Gaussian Process Regression dengan Matérn kernel tanpa optimasi menghasilkan kinerja yang cukup baik dengan MAE sebesar 85.65, RMSE sebesar 108.70, MAPE sebesar 0.53%, dan R^2 sebesar 0.91. Nilai MAE dan RMSE yang relatif kecil menunjukkan bahwa rata-rata kesalahan prediksi terhadap nilai aktual berada dalam rentang 80–100 poin, yang lebih baik dibandingkan dengan hasil kernel Rational Quadratic tanpa optimasi. Nilai MAPE yang rendah, di bawah 1%, memperlihatkan bahwa kesalahan relatif model terhadap data aktual sangat kecil sehingga prediksi dapat dianggap sangat presisi. Sementara itu, nilai koefisien determinasi (R^2) sebesar 0.91

mengindikasikan bahwa model mampu menjelaskan 91% variasi dalam data kurs USD-IDR, menandakan kemampuan prediksi yang sangat baik dan tingkat akurasi yang tinggi meskipun dilakukan tanpa optimasi parameter.



Gambar 6. Hasil Visualisasi Matern Kernel Tanpa Optimasi

Grafik *Actual vs Predicted* memperlihatkan perbandingan antara nilai aktual kurs USD-IDR (garis biru) dengan prediksi model (garis oranye putus-putus) pada periode data uji. Secara umum, pola pergerakan prediksi sangat mendekati data aktual, baik ketika terjadi tren kenaikan, penurunan, maupun fluktuasi jangka pendek. Model dengan Matérn kernel terlihat lebih adaptif dalam mengikuti dinamika pasar dibandingkan dengan Rational Quadratic kernel tanpa optimasi, karena mampu menangkap perubahan tajam dengan lebih baik. Meski masih terdapat sedikit deviasi pada beberapa titik ekstrem, garis prediksi hampir selalu berimpit dengan garis aktual, menandakan tingkat kecocokan yang sangat baik. Visualisasi ini memperkuat hasil metrik evaluasi yang menunjukkan performa unggul dari Matérn kernel tanpa optimasi dalam memodelkan kurs USD-IDR.


5. Uji Kernel Rational Quadratic Dengan Optimasi Hyperband

Berikut adalah bagian uji coba untuk kernel Matern yang dilakukan tanpa optimasi dengan target variable nilai tukar

```
Trial 21:
MAE : 49.0630
RMSE : 64.5914
MAPE : 0.3033
R2 : 0.9693
```

Gambar 7. Hasil Metriks Evaluasi RQ Kernel dengan Optimasi Hyperparameter

Hasil pengujian menggunakan Rational Quadratic Kernel dengan optimasi hyperparameter menunjukkan performa yang sangat baik. Nilai MAE (Mean Absolute Error) sebesar 49.06 menandakan rata-rata kesalahan prediksi hanya sekitar 49 Rupiah dari nilai aktual. RMSE (Root Mean Squared Error) sebesar 64.60 juga relatif rendah, yang berarti kesalahan kuadrat rata-rata pada model cukup kecil. Selain itu, MAPE (Mean Absolute Percentage Error) sebesar 0.30% mengindikasikan tingkat kesalahan persentase yang sangat rendah, menunjukkan bahwa model mampu memprediksi dengan tingkat akurasi tinggi. Terakhir, nilai R^2 sebesar 0.9693 memperlihatkan bahwa model dapat menjelaskan sekitar 96,93% variasi dari data aktual, sehingga model memiliki kemampuan generalisasi yang sangat baik.



Gambar 8. Hasil Visualisasi RQ Kernel Dengan Optimasi

Pada grafik, garis biru mewakili nilai aktual pergerakan kurs USD-IDR, sedangkan garis oranye putus-putus menunjukkan hasil prediksi model dengan kernel Rational Quadratic yang telah dioptimasi. Pola keduanya terlihat hampir berimpit sepanjang periode pengujian, menunjukkan bahwa model mampu mengikuti tren jangka panjang maupun fluktuasi jangka pendek secara akurat. Hanya terdapat sedikit deviasi pada titik-titik tertentu, namun secara keseluruhan prediksi sangat konsisten dengan data aktual. Visualisasi ini menguatkan hasil metrik evaluasi, di mana model berhasil memberikan estimasi nilai tukar dengan tingkat kesalahan yang sangat kecil dan korelasi yang tinggi terhadap data nyata.


6. Uji Matern Kernel Dengan Iptimasi Hyperband

Berikut adalah bagian uji coba untuk kernel Matern yang dilakukan tanpa optimasi dengan target variable nilai tukar

```
Matern Trial A (nu=2.0999):  
MAE : 49.6177  
RMSE : 65.0032  
MAPE : 0.3067  
R2 : 0.9689
```

Gambar 9. Hasil Matriks Evaluasi Matern Kernel Dengan Optimasi

Hasil pengujian dengan Matern Kernel yang telah dioptimasi menunjukkan performa prediksi yang sangat baik. Nilai MAE (Mean Absolute Error) sebesar 49.62 mengindikasikan bahwa rata-rata kesalahan prediksi hanya sekitar 49 Rupiah dari nilai aktual, yang relatif kecil dibandingkan dengan skala nilai tukar. RMSE (Root Mean Squared Error) sebesar 65.00 juga memperlihatkan kesalahan kuadrat rata-rata yang rendah, sehingga model tidak banyak menghasilkan prediksi ekstrem yang menyimpang jauh dari nilai sebenarnya. Selanjutnya, MAPE (Mean Absolute Percentage Error) sebesar 0.31% menunjukkan tingkat kesalahan persentase yang sangat kecil, menandakan akurasi prediksi yang tinggi. Terakhir, nilai R^2 sebesar 0.9689 memperlihatkan bahwa model mampu menjelaskan sekitar 96,89% variasi data, yang menegaskan kemampuan generalisasi model dalam menangkap pola pergerakan kurs USD-IDR.



Gambar 10. Hasil Visualiasi Matern Kernel Dengan Optimasi

Pada grafik, garis biru menggambarkan nilai aktual kurs USD-IDR, sedangkan garis oranye putus-putus merepresentasikan hasil prediksi dari model Matern Kernel yang sudah dioptimasi. Pola kedua garis terlihat hampir berhimpit sepanjang periode pengujian, menunjukkan kemampuan model dalam mengikuti tren jangka panjang maupun fluktuasi jangka pendek dengan presisi tinggi. Hampir tidak ada deviasi besar antara garis aktual dan prediksi, kecuali pada beberapa titik

puncak atau lembah yang sifatnya minor. Visualisasi ini mengonfirmasi metrik evaluasi yang diperoleh, bahwa model mampu mereplikasi pola pergerakan kurs dengan sangat akurat serta meminimalisir kesalahan prediksi.

B. Pembahasan

Berikut adalah table untuk membandingkan hasil dari uji coba Rational Quadratic dengan Matern Kernel setelah dioptimasi dan sebelum dioptimasi.

Tabel 1. Perbandingan Akurasi

Kernel	Akurasi Sebelum Optimasi	Akurasi Sesudah Optimasi
Rational Quadratic (RQ) Kernel	74.01%	96.93
Matern Kernel	91.32%	98.89%

Hasil pengujian menunjukkan adanya perbedaan yang cukup signifikan antara kinerja model sebelum dan sesudah dilakukan optimasi hyperparameter pada kedua kernel yang digunakan, yaitu dan Matern. Pada kernel Rational Quadratic, nilai akurasi yang diukur dengan koefisien determinasi (R^2) mengalami peningkatan yang sangat besar, dari 74,01% sebelum optimasi menjadi 96,93% setelah optimasi, atau naik sekitar 22,92%. Hal ini menunjukkan bahwa proses optimasi berhasil secara drastis memperbaiki kemampuan model dalam menangkap pola data nilai tukar USD-IDR. Sementara itu, kernel Matern yang sebelumnya sudah memiliki performa cukup tinggi dengan akurasi 91,32%, juga menunjukkan peningkatan setelah optimasi dengan mencapai 96,89%, atau naik sekitar 5,57%. Walaupun peningkatannya tidak sebesar kernel RQ, hasil ini menegaskan bahwa optimasi tetap memberikan dampak positif terhadap peningkatan akurasi. Secara keseluruhan, perbandingan ini membuktikan bahwa penggunaan metode optimasi hyperparameter sangat krusial untuk menghasilkan model Gaussian Process Regression (GPR) yang lebih andal dan akurat, terutama pada kernel yang awalnya menunjukkan performa kurang optimal.

IV. SIMPULAN DAN SARAN

A. Simpulan

Penelitian ini membahas implementasi Gaussian Process Regression (GPR) dengan dua jenis kernel, yaitu Rational Quadratic (RQ) dan Matern, dalam memprediksi nilai

tukar USD-IDR. Hasil pengujian menunjukkan bahwa kedua kernel mampu memberikan prediksi yang cukup akurat, namun performa model meningkat secara signifikan setelah dilakukan optimasi hyperparameter menggunakan metode Hyperband. Kernel Rational Quadratic yang semula memiliki akurasi rendah berhasil ditingkatkan secara drastis hingga mencapai tingkat akurasi sebanding dengan kernel Matern, sedangkan kernel Matern yang sebelumnya sudah cukup baik juga mengalami peningkatan meski dalam skala yang lebih kecil. Temuan ini menegaskan pentingnya optimasi hyperparameter dalam meningkatkan kinerja model, sekaligus menunjukkan bahwa GPR dengan kernel RQ maupun Matern dapat menjadi alternatif yang handal untuk pemodelan deret waktu nilai tukar. Dengan demikian, penelitian ini memberikan kontribusi dalam memperkaya literatur mengenai penerapan GPR di bidang keuangan, serta membuka peluang penelitian lanjutan yang dapat memperluas variabel eksternal atau mengintegrasikan pendekatan hibrida guna memperoleh hasil prediksi yang lebih presisi.

B. Saran

Untuk penelitian yang Selanjutnya disarankan agar menggunakan kernel yang lain dan menambah jumlah factor eksternal yang lain. Disarankan pula untuk menambah metode atau menggunakan metode yang lain sebagai model Prediksi ataupun model Hyperparameter nya.

DAFTAR RUJUKAN

- Abisa, J. and Munir, M., 2024. Faktor-faktor yang memengaruhi nilai tukar Rupiah terhadap Dolar Amerika Serikat. *Jurnal Ilmu Ekonomi*, [online] 5(1), pp.14–19. Available at: <http://jurnal.unsil.ac.id/index.php/welfare>
- Akbari, E., Bolorani, A.D., Verrelst, J., Pignatti, S., Neysani Samany, N., Soufizadeh, S. and Hamzeh, S., 2023. Biophysical Variable Retrieval of Silage Maize with Gaussian Process Regression and Hyperparameter Optimization Algorithms. *Remote Sensing*, 15(14). <https://doi.org/10.3390/rs15143690>.
- Iversen, M.V., 2020. Combining Hyperband and Gaussian Process-based Bayesian Optimization. (June).
- Jarwadi, M.H., Jusuf, A., Satria Palar, P., Gunawan B A Program, L., Dirgantara, P.T., Keahlian, K., Ringan, S. and Terbang, F., n.d. Optimizing crash box design for enhanced vehicle safety: A Gaussian process regression approach. pp.21–26.
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A. and Talwalkar, A., 2018. Hyperband: A novel bandit-based approach to hyperparameter optimization. *Journal of Machine Learning Research*, 18, pp.1–52.
- Mirshekari, S., Moradi, M., Ensaf, M., Jafari, H. and Jafari, M., 2024. Enhancing Predictive Accuracy in Pharmaceutical Sales Through an Ensemble Kernel Gaussian Process Regression Approach. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4860667>.
- Sachdeva, S. and Kumar, B., 2021. A novel ensemble model of automatic multilayer perceptron, random forest, and ZeroR for groundwater potential mapping. *Environmental Monitoring and Assessment*, [online] 193(11), p.722. <https://doi.org/10.1007/s10661-021-09519-8>.
- Shao, Z. and Kumral, M., 2024. Implementing Gaussian process modelling in predictive maintenance of mining machineries. *Mining Technology: Transactions of the Institutions of Mining and Metallurgy*, 133(4), pp.348–368. <https://doi.org/10.1177/25726668241275434>.
- Shi, X., Jiang, D., Qian, W. and Liang, Y., 2022. Application of the Gaussian Process Regression Method Based on a Combined Kernel Function in Engine Performance Prediction. *ACS Omega*, 7(45), pp.41732–41743. <https://doi.org/10.1021/acsomega.2c05952>.
- Suphawan, K., Kardkasem, R. and Chaisee, K., 2022. A Gaussian Process Regression Model for Forecasting Stock Exchange of Thailand. *Trends in Sciences*, 19(6). <https://doi.org/10.48048/tis.2022.3045>.
- Triyono, T., 2008. Analisis Perubahan Kurs Rupiah Terhadap Dollar Amerika. *Jurnal Ekonomi Pembangunan: Kajian Masalah*

Ekonomi dan Pembangunan, 9(2), p.156.
<https://doi.org/10.23917/jep.v9i2.1022>.

Wang, J., 2023. An Intuitive Tutorial to Gaussian Process Regression. *Computing in Science and Engineering*, 25(4), pp.4–11.
<https://doi.org/10.1109/MCSE.2023.3342149>.

Xu, B., Kuplicki, R., Sen, S. and Paulus, M.P., 2021. The pitfalls of using Gaussian Process Regression for normative modeling. *PLoS ONE*, [online] 16(9 September), pp.1–14.
<https://doi.org/10.1371/journal.pone.0252108>.

Yadav, A., Bareth, R., Kochar, M., Pazoki, M. and Sehiemy, R.A.E., 2024. Gaussian process regression-based load forecasting model. *IET Generation, Transmission and Distribution*, 18(5), pp.899–910.
<https://doi.org/10.1049/gtd2.12926>.