

**PREDIKSI HARGA KOMODITAS KARET MENGGUNAKAN
*SUPPORT VECTOR REGRESSION (SVR)***

SKRIPSI

Oleh :
Achmad Yusni Muzakky
NIM. 220605110026



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

**PREDIKSI HARGA KOMODITAS KARET MENGGUNAKAN
*SUPPORT VECTOR REGRESSION (SVR)***

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
Achmad Yusni Muzakky
NIM. 220605110026

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN

PREDIKSI HARGA KOMODITAS KARET MENGGUNAKAN *SUPPORT VECTOR REGRESSION (SVR)*

SKRIPSI


Oleh :
ACHMAD YUSNI MUZAKKY
NIM. 220605110026

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 11 Juni 2026

Pembimbing I,


Dr. Totok Chamidy, M.Kom
NIP. 19691222 200604 1 001

Pembimbing II,


A'la Syauqi, M.Kom
NIP. 19771201 200801 1 007

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Maulana Malik Ibrahim Malang




Syarifuddin, M.Kom
NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

PREDIKSI HARGA KOMODITAS KARET MENGGUNAKAN *SUPPORT VECTOR REGRESSION (SVR)*

SKRIPSI

Oleh :
ACHMAD YUSNI MUZAKKY
NIM. 220605110026

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 23 Juni 2026

Susunan Dewan Penguji

Ketua Penguji	: <u>Dr. Agung Teguh Wibowo Almais, M.T</u> NIP. 19860301 202321 1 016
Anggota Penguji I	: <u>Ashri Shabrina Afrah, M.T</u> NIP. 19900403 202012 2 003
Anggota Penguji II	: <u>Dr. Totok Chamidy, M.Kom</u> NIP. 19691222 200604 1 001
Anggota Penguji III	: <u>A'la Syauqi, M.Kom</u> NIP. 19771201 200801 1 007

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam ABUL MALIK Ibrahim Malang



PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Achmad Yusni Muzakky
NIM : 220605110026
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Prediksi Harga Komoditas Karet Menggunakan
Support Vector Regression (SVR).

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 23 Juni 2026
Yang membuat pernyataan,



Achmad Yusni Muzakky
NIM.220605110026

MOTTO

“Barang siapa yang tidak mampu menahan lelahnya belajar, maka ia harus mampu menahan perihnya kebodohan.”

Imam Syafi'i

HALAMAN PERSEMBAHAN

Alhamdulillah, segala puji bagi Allah Swt. atas segala rahmat, pertolongan, dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini.

Dengan penuh rasa syukur, hormat, dan terima kasih, persembahkan kepada mereka yang senantiasa menjadi sumber doa, kekuatan, dan semangat dalam setiap langkah.

Terima kasih kepada diri sendiri yang telah berjuang, bertahan, dan tidak menyerah dalam menyelesaikan setiap proses perkuliahan hingga penyusunan skripsi ini. Semoga pencapaian ini menjadi awal dari langkah-langkah yang lebih baik, bermanfaat, dan penuh keberkahan.

Karya sederhana ini juga penulis persembahkan kepada kedua orang tua tercinta yang senantiasa memberikan doa, kasih sayang, dukungan, serta pengorbanan tanpa henti. Terima kasih atas segala kepercayaan, nasihat, dan cinta yang selalu menjadi kekuatan dalam setiap langkah. Semoga Allah Swt. senantiasa melimpahkan kesehatan, kebahagiaan, dan keberkahan kepada beliau berdua serta membalas seluruh kebaikan dengan balasan yang terbaik.

KATA PENGANTAR

Alhamdulillahirabbil ‘alamin, segala puji dan syukur penulis panjatkan ke hadirat Allah Subhanahu wa Ta’ala atas limpahan rahmat, taufik, dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Prediksi Harga Komoditas Karet Menggunakan *Support Vector Regression* (SVR)” dengan baik. Penulis menyadari bahwa dalam proses penyusunan skripsi ini terdapat berbagai keterbatasan dan tantangan, namun berkat bantuan, bimbingan, dukungan, serta motivasi dari berbagai pihak, skripsi ini dapat diselesaikan dengan baik. Ucapan ini penulis sampaikan kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., CAHRM., CRMP. selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes. selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Supriyono, M. Kom, selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang dan Dr. Ir. Fachrul Kurniawan, M.MT., IPU. selaku dosen wali saya yang telah mendampingi saya secara akademik selama perkuliahan.
4. Dr. Totok Chamidy, M.Kom., selaku Dosen Pembimbing I, yang telah dengan sabar meluangkan waktu dan memberikan arahan serta bimbingan yang berarti selama proses penyusunan skripsi ini.
5. A’la Syauqi, M.Kom., selaku Dosen Pembimbing II, yang telah memberikan banyak dukungan dan bimbingan dalam penulisan skripsi ini.

6. Dr. Agung Teguh Wibowo Almais, M.T., selaku Ketua Penguji dan Ashri Shabrina Afrah, M.T., selaku Anggota Penguji 1, atas segala saran, masukan, dan arahan, serta kesediaan beliau yang senantiasa meluangkan waktu untuk mendampingi, sehingga penulis dapat mempersiapkan diri dengan lebih baik.
7. Seluruh Dosen, Admin, dan Staf Program Studi Teknik Informatika, yang telah berbagi ilmu, tenaga, dan kebaikan selama masa studi ini.
8. Kedua orang tua dan keluarga, Terima kasih atas dukungan doa, cinta yang sangat tulus, doa yang tak pernah terputus, serta semangat yang senantiasa menguatkan, Berkat pengorbanan dan usaha beliau berdua, penulis dapat sampai sejauh ini.
9. Teman-teman Infinity, yang selalu menemani dan membantu penulis sejak awal perkuliahan. Terima kasih telah menjadi tempat berbagi cerita dan saksi perjalanan panjang serta kebersamaan.
10. Untuk seseorang yang sudah menemani mulai awal perkuliahan hingga saat ini, Terima kasih atas kesediaan untuk senantiasa mendampingi dan membantu penulis dalam setiap proses yang dilalui, dan menjadi saksi perjalanan dalam setiap langkah dari awal perkuliahan hingga penulis mencapai tahap akhir penyelesaian skripsi ini.

Malang, 23 Juni 2026

Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO... ..	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR GAMBAR.....	xii
DAFTAR TABEL	xiii
ABSTRAK	xiv
ABSTRACT	xv
مستخلص البحث.....	xvi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah.....	5
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA	7
2.1 Penelitian Terkait	7
2.2 Komoditas Karet	11
2.3 Prediksi (<i>Forecasting</i>).....	13
2. Data <i>Time Series</i>	15
2.5 Pra-pemrosesan Data.....	16
2. <i>Support Vector Regression</i> (SVR)	19
2.7 Parameter <i>Support Vector Regression</i>	21
2.8 Algoritma <i>Grid Search</i>	22
2.9 <i>Root Mean Squared Error</i> (RMSE)	23
BAB III DESAIN DAN IMPLEMENTASI	25
3.1 Desain Penelitian.....	25
3.2 Pengumpulan Data	25
3.2.1 Analisis Deskriptif	26
3.3 Perancangan Desain Sistem	27
3.4 Optimasi Algoritma <i>Grid Search</i>	29
3.5 Implementasi <i>Support Vector Regression</i>	30

3.5.1 Persiapan Data	31
3.5.2 <i>Feature Engineering</i>	31
3.5.3 Normalisasi	32
3.5.4 Perhitungan dengan kernel <i>Radial Basis Function</i>	33
3.5.5 Optimasi <i>Hyperparameter</i>	34
4.1.1 Menghitung Prediksi	35
4.1.2 Menghitung RMSE	36
3.6 Skenario Pengujian	36
BAB IV HASIL DAN PEMBAHASAN	38
4.2 Hasil... ..	38
4.2.1 Input Data	38
4.1.2 Pra-pemrosesan Data	39
4.1.3 Pelatihan Model Support Vector Regression	41
4.3 Hasil Evaluasi Model	49
4.3.1 Hasil Evaluasi Model Tanpa Optimasi Hyperparameter	49
4.3.2 Hasil Evaluasi Model dengan Optimasi <i>Hyperparameter</i>	53
4.3.3 Perbandingan Kinerja Model <i>Support Vector Regression</i> (SVR)	56
4.4 Pembahasan	60
4.5 Integrasi Islam	64
4.5.1 Konsep Perencanaan Dalam Perspektif Alqur'an	65
4.5.2 Pengambilan Keputusan Dalam Perspektif Islam	66
BAB V KESIMPULAN DAN SARAN	69
5.1 Kesimpulan	69
5.2 Saran	70
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 3.1 Desain Penelitian.....	25
Gambar 3.2 Grafik Harga Karet Tahun 2000-2020 (<i>IndexMundi</i>)	26
Gambar 3.3 Desain Sistem.....	28
Gambar 3.4 <i>Hyperplane</i>	30
Gambar 4.1 Perbandingan Nilai Aktual dan Prediksi Tanpa Optimasi	43
Gambar 4.2 Perbandingan Nilai Aktual dan Prediksi dengan <i>Grid Search</i>	48
Gambar 4.3 Visualisasi Hasil Prediksi Model Tanpa Optimasi.....	52
Gambar 4.4 Hasil Prediksi Model dengan Optimasi <i>Hyperparameter</i>	55
Gambar 4.5 Visualisasi Perbandingan Hasil Prediksi Model	59
Gambar 4.6 Pengaruh Parameter <i>C</i>	60
Gambar 4.7 Pengaruh Parameter <i>Epsilon</i>	62
Gambar 4.8 Pengaruh Parameter <i>Gamma</i>	63

DAFTAR TABEL

Tabel 3.1 Analisis Dekriptif.....	27
Tabel 3.2 Harga Karet Dunia tahun 2000	31
Tabel 3.3 Lag feature	32
Tabel 3.4 Data setelah dinormalisasi	33
Tabel 3.5 Nilai Alpha setiap titik data	34
Tabel 3.6 Data hasil prediksi.....	35
Tabel 4.1 Data Harga Karet	38
Tabel 4.2 <i>Lag Feature</i>	39
Tabel 4.3 Pembagian Data	40
Tabel 4.4 Normalisasi <i>Min-Max Scaler</i>	41
Tabel 4.5 Parameter Model Tanpa Optimasi	41
Tabel 4.6 Hasil <i>Training</i> Model Tanpa Optimasi	42
Tabel 4.7 Pencarian Hyperparameter dengan <i>Grid Search</i>	44
Tabel 4.8 Hasil Evaluasi Kombinasi <i>Hyperparameter</i>	45
Tabel 4.9 Parameter Terbaik Hasil Optimasi <i>Grid Search</i>	47
Tabel 4.10 Hasil <i>Training</i> Model dengan <i>Grid Search</i>	47
Tabel 4.11 Hasil Prediksi Model Tanpa Optimasi <i>Hyperparameter</i>	50
Tabel 4.12 Hasil Prediksi Model dengan Optimasi <i>Hyperparameter</i>	53
Tabel 4.13 Perbandingan Hasil Prediksi Model.....	57

ABSTRAK

Muzakky, Achmad Yusni. 2026. **Prediksi Harga Komoditas Karet Menggunakan *Support Vector Regression* (SVR)**. Skripsi. Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Totok Chamidy, M.Kom (II) A'la Syauqi, M.Kom.

Kata kunci: *Grid Search, Prediksi Harga Karet, Radial Basis Function, Root Mean Squared Error, Support Vector Regression.*

Harga karet alam merupakan data deret waktu yang memiliki karakteristik nonlinier dan volatil sehingga menimbulkan tantangan dalam proses prediksi. Penelitian ini bertujuan untuk mengevaluasi kinerja *Support Vector Regression* (SVR) dengan *kernel Radial Basis Function* (RBF) serta mengkaji pengaruh optimasi *hyperparameter* menggunakan *Grid Search* dalam prediksi harga karet alam. Data yang digunakan berupa data harga karet global bulanan periode Januari 2000 hingga Desember 2020 yang diperoleh dari *IndexMundi* dengan total 252 observasi. Penelitian dilakukan melalui dua skenario, yaitu SVR tanpa optimasi *hyperparameter* dan SVR dengan optimasi *hyperparameter* menggunakan *Grid Search*. Evaluasi kinerja model dilakukan menggunakan *Root Mean Squared Error* (RMSE) pada data pengujian periode Januari 2018 hingga Desember 2020. Hasil penelitian menunjukkan bahwa optimasi *hyperparameter* mampu meningkatkan kinerja model dengan menurunkan nilai RMSE dari 0.188203 menjadi 0.115199. Kombinasi *hyperparameter* terbaik yang diperoleh adalah $C = 100$, $\epsilon = 0.01$, dan $\gamma = 0.1$ dengan nilai RMSE validasi silang sebesar 0.038695. Hasil penelitian ini menunjukkan bahwa SVR dengan kernel RBF yang dioptimasi menggunakan *Grid Search* memiliki kemampuan yang lebih baik dalam memprediksi harga karet alam dan berpotensi menjadi pendukung pengambilan keputusan bagi petani, pelaku industri, maupun pemerintah.

ABSTRACT

Muzakky, Achmad Yusni. 2026. **Prediction of Rubber Commodity Prices Using Support Vector Regression (SVR)**. Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University Malang. Supervisor: (I) Dr. Totok Chamidy, M.Kom (II) A'la Syauqi, M.Kom.

Keywords: *Grid Search, Rubber Price Prediction, Radial Basis Function, Root Mean Squared Error, Support Vector Regression.*

Natural rubber prices constitute a time-series dataset characterized by nonlinear and volatile patterns, making the prediction process challenging. This study aims to evaluate the performance of Support Vector Regression (SVR) with a Radial Basis Function (RBF) kernel and to examine the effect of hyperparameter optimization using Grid Search on natural rubber price prediction. The dataset consists of monthly global rubber prices from January 2000 to December 2020 obtained from IndexMundi, comprising a total of 252 observations. The study was conducted using two scenarios: SVR without hyperparameter optimization and SVR with hyperparameter optimization using Grid Search. Model performance was evaluated using Root Mean Squared Error (RMSE) on the testing data covering the period from January 2018 to December 2020. The results indicate that hyperparameter optimization improved model performance by reducing the RMSE from 0.188203 to 0.115199. The best hyperparameter combination obtained was $C = 100$, $\epsilon = 0.01$, and $\gamma = 0.1$, achieving a cross-validation RMSE of 0.038695. The findings demonstrate that SVR with an RBF kernel optimized through Grid Search provides better predictive performance for natural rubber prices and has the potential to support decision-making processes for farmers, industry stakeholders, and policymakers.

مستخلص البحث

مركي، احمد يوسني. ٢٠٢٦. التنبؤ بأسعار المطاط باستخدام انحدار متجه الدعم (SVR). البحث العلم. قسم هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية بمالانج. المشرفان: (١) د. توتوك شاميدي، ماجستير علوم حاسوب. (٢) علاء شوقي، ماجستير علوم حاسوب.

الكلمات المفتاحية: البحث الشبكي، التنبؤ بسعر المطاط، دالة الأساس الشعاعي، جذر متوسط مربع الخطأ، انحدار متجه الدعم.

إنَّ أسعار المطاط الطبيعي هي بيانات سلاسل زمنية تتميز بخصائص غير خطية ومتقلبة، مما يشكل تحديًا في عملية التنبؤ. تهدف هذه الدراسة إلى تقييم أداء انحدار المتجهات الداعمة (SVR) باستخدام نواة دالة الأساس الشعاعي (RBF)، بالإضافة إلى دراسة تأثير تحسين المعلومات الفائقة (Hyperparameter Optimization) باستخدام البحث الشبكي (Grid Search) في التنبؤ بأسعار المطاط الطبيعي. البيانات المستخدمة هي بيانات أسعار المطاط العالمية الشهرية للفترة من يناير ٢٠٠٠ إلى ديسمبر ٢٠٢٠، والتي تم الحصول عليها من موقع (IndexMundi) بإجمالي ٢٥٢ ملاحظة. أُجريت الدراسة من خلال سيناريوهين: الأول هو (SVR) بدون تحسين المعلومات الفائقة، والثاني هو (SVR) مع تحسين المعلومات الفائقة باستخدام البحث الشبكي. وتم تقييم أداء النموذج باستخدام جذر متوسط مربع الخطأ (RMSE) على بيانات الاختبار للفترة من يناير ٢٠١٨ إلى ديسمبر ٢٠٢٠. وأظهرت النتائج أن تحسين المعلومات الفائقة قادر على رفع كفاءة أداء النموذج من خلال خفض قيمة (RMSE) من ٠,١٨٨٢٠٣ إلى ٠,١١٥١٩٩. وكانت أفضل توليفة معاملات فائقة تم الحصول عليها هي $C = 1.0$, $\epsilon = 0.01$, $\gamma = 0.01$. مع قيمة (RMSE) للتحقق المتبادل بلغت ٠,٠٣٨٦٩٥. وتُشير نتائج هذه الدراسة إلى أن نموذج (SVR) بنواة (RBF) المحسّن بواسطة البحث الشبكي يمتلك قدرة أفضل على التنبؤ بأسعار المطاط الطبيعي، وله القدرة على أن يكون أداة لدعم اتخاذ القرار للمزارعين، والفاعلين في القطاع الصناعي، والحكومة

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam perekonomian Indonesia, sektor perkebunan menduduki peran yang strategis. Kontribusinya mencakup sumbangan terhadap Produk Domestik Bruto (PDB) dan serapan tenaga kerja yang masif, terutama dari komoditas andalan. Selain menjadi penopang ketahanan pangan skala nasional, sektor ini juga menggerakkan pembangunan perdesaan yang menjadi andalan hidup masyarakat luas. Tak kalah penting, perkebunan memberikan kontribusi devisa yang besar melalui ekspor komoditas utama, seperti kelapa sawit, kopi, dan teh (Purwoko et al., 2023). Di tingkat global, komoditas perkebunan kini semakin terpengaruh oleh fluktuasi harga dan dinamika pasar. Akibatnya, ketepatan informasi serta akurasi prediksi harga menjadi faktor krusial dalam tata kelola sektor ini (Guindani et al., 2024).

Di antara komoditas perkebunan, karet alam menempati posisi istimewa karena fungsinya yang ganda: sebagai bahan baku industri sekaligus sumber pendapatan pokok bagi masyarakat di kawasan sentra produksi. Komoditas ini menjadi tulang punggung peningkatan kesejahteraan petani, mengingat sebagian besar produksinya berasal dari perkebunan rakyat. Kedudukan strategis tersebut membuat karet alam terus menjadi prioritas dalam pengembangan agribisnis nasional maupun perumusan kebijakan perkebunan (Krismawan et al., 2021).

Indonesia termasuk tiga besar produsen dan eksportir karet alam dunia, bersama Thailand dan Malaysia. Data Statistik Karet Indonesia 2023 menunjukkan luas areal perkebunan karet nasional mencapai 3,15 juta hektare, turun dari 3,78 juta hektare pada 2021. Penurunan ini terutama terjadi pada lahan perkebunan rakyat, yang dipicu oleh tekanan harga komoditas yang rendah dalam beberapa tahun terakhir (Solimah et al., 2024). Meski demikian, sektor karet tetap menjadi tumpuan ekonomi di wilayah-wilayah penghasil seperti Sumatera Selatan, Jambi, Riau, dan Kalimantan Barat.

Dalam perdagangan internasional, karet tergolong komoditas ekspor nonmigas yang memberi kontribusi berarti terhadap pemasukan devisa negara. Berdasarkan data Kementerian Pertanian, ekspor karet Indonesia ke Amerika Serikat pada 2024 mencapai 370,7 ribu ton dengan nilai USD 673,1 juta, atau setara dengan sekitar 22 persen dari total ekspor karet nasional (Pusat Data dan Sistem Informasi, 2025). Akan tetapi, pada kurun 2018–2023, ekspor karet Indonesia menunjukkan tren penurunan rata-rata 13,7 persen per tahun, yang disebabkan oleh fluktuasi harga global dan ketidakpastian permintaan. Sejumlah penelitian mengungkapkan bahwa harga karet domestik sangat dipengaruhi oleh harga internasional, kurs nilai tukar, dan harga periode sebelumnya, sehingga komoditas ini rentan terhadap guncangan ekonomi dunia (Suri et al., 2021).

Sifat fluktuasi harga karet yang non-linear dan volatil menimbulkan ketidakpastian bagi petani maupun pelaku industri dalam mengambil keputusan. Pola data yang rumit dan tidak linear membuat model konvensional seperti regresi linier dan *Autoregressive Integrated Moving Average* (ARIMA) menghadapi

kendala, karena kedua metode tersebut pada dasarnya mengasumsikan hubungan yang linear serta data yang *stasioner*. Penelitian oleh Ngestisari et al. (2020) menunjukkan bahwa ARIMA memiliki akurasi lebih rendah dibandingkan jaringan syaraf tiruan dalam memprediksi harga beras akibat ketidakmampuannya mengikuti pola non-linear. Temuan serupa disampaikan oleh Nadir & Sukmana (2023), yang menyatakan bahwa metode ANN lebih efektif dibandingkan model statistik tradisional dalam memproses data yang berfluktuasi seperti harga emas.

Selain itu, Sihombing et al. (2022) menunjukkan bahwa integrasi ARIMA dengan *Support Vector Regression* (SVR) dapat meningkatkan akurasi prediksi indeks harga saham, karena SVR mampu menangkap non-linearitas yang tidak dapat dimodelkan oleh ARIMA. Dengan demikian, penggunaan metode *machine learning*, khususnya *Support Vector Regression* (SVR), menjadi relevan untuk memodelkan dinamika harga karet yang kompleks dan *volatil*. SVR mampu menangkap data non-linear dan variabilitas tinggi, sehingga memberikan akurasi prediksi lebih baik dibanding metode tradisional (Azis et al., 2023a). Namun, penelitian yang secara khusus mengembangkan model prediksi harga karet berbasis SVR dengan optimasi parameter terbaik masih terbatas, sehingga menjadi fokus penelitian ini.

Selain berperan dalam perdagangan, karet juga memiliki peran strategis bagi industri domestik. Industri berbasis karet sangat bergantung pada pasokan dan harga karet alam. Fluktuasi harga yang tinggi tidak hanya berdampak pada petani dan eksportir, tetapi juga pada efisiensi produksi dan daya saing industri domestik. Ketersediaan informasi harga yang akurat dan kemampuan memprediksi tren harga

menjadi penting untuk menjaga stabilitas pasokan, perencanaan produksi, dan strategi industri (Ngatemi et al., 2022).

Firman Allah Swt. dalam Surah Yusuf ayat 47-49 menggambarkan konsep perencanaan jangka panjang yang dilakukan Nabi Yusuf dalam menghadapi paceklik:

قَالَ تَزْرَعُونَ سَبْعَ سِنِينَ دَأَبًا فَمَا حَصَدْتُمْ فَذَرُوهُ فِي سُنْبُلِهِ إِلَّا قَلِيلًا مِّمَّا تَأْكُلُونَ ﴿٤٧﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ سَبْعٌ شِدَادٌ يَأْكُلْنَ مَا قَدَّمْتُمْ لَهُنَّ إِلَّا قَلِيلًا مِّمَّا تُخْصِنُونَ ﴿٤٨﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ عَامٌ فِيهِ يُغَاثُ النَّاسُ وَفِيهِ يَعْرِضُونَ ﴿٤٩﴾

(Yusuf) berkata, “Bercocoktanamlah kamu tujuh tahun berturut-turut! Kemudian apa yang kamu tuai, biarkanlah di tangkainya, kecuali sedikit untuk kamu makan. Kemudian, sesudah itu akan datang tujuh (tahun) yang sangat sulit (paceklik) yang menghabiskan apa yang kamu simpan untuk menghadapinya, kecuali sedikit dari apa (bibit gandum) yang kamu simpan. Setelah itu akan datang tahun, ketika manusia diberi hujan (dengan cukup) dan pada masa itu mereka memeras (anggur).” (Q.S Yusuf: 47-49)

Ayat tersebut menggambarkan strategi pengelolaan sumber daya yang terencana dengan berlandaskan pada prediksi keadaan di masa yang akan datang. Para ahli tafsir, termasuk kajian semiotika yang dilakukan Hadi (2022), menekankan bahwa anjuran untuk bertanam secara terus-menerus dan menyimpan hasil panen pada tangkainya merupakan wujud kebijakan yang bertumpu pada analisis pola. Prinsip perencanaan yang terkandung dalam ayat ini memiliki relevansi dengan praktik *forecasting*, di mana data masa lalu diolah untuk memprediksi kondisi yang akan datang secara terstruktur, yakni prediksi berbasis pola atau tren historis guna optimalisasi keputusan. Pandangan ini menjadi landasan filosofis bagi pemanfaatan teknik prediksi seperti *Support Vector Regression*

(SVR), yang bertujuan mendeteksi tren data, meramalkan perubahan ke depan, serta memberikan manfaat konkret dalam penyusunan perencanaan ekonomi.

Dalam kondisi ideal, stabilitas harga karet akan memberi kepastian ekonomi bagi seluruh pihak yang berkepentingan, mencakup petani, pelaku industri, maupun pemerintah. Akan tetapi, pada praktiknya harga karet cenderung bergerak fluktuatif dan sulit diprakirakan akibat pengaruh berbagai faktor eksternal yang rumit (Sasmi et al., 2023). Karena itu, diperlukan pendekatan prediksi yang mampu menangkap pola dalam data harga komoditas karet. Berdasarkan pemaparan tersebut, penelitian ini bertujuan untuk menyusun model prediksi harga karet dengan menggunakan *Support Vector Regression* (SVR) yang dioptimalkan melalui pemilihan parameter terbaik. Model ini diharapkan mampu menghasilkan prediksi yang akurat dan konsisten, sekaligus menjadi landasan perencanaan ekonomi bagi petani, pelaku usaha, dan pengambil kebijakan dalam menghadapi dinamika harga karet yang kompleks.

1.2 Rumusan Masalah

Bagaimana penerapan metode *Support Vector Regression* dalam memprediksi harga komoditas karet berbasis data *time series*, serta bagaimana pemilihan parameter yang optimal dengan *Grid Search* dapat meningkatkan akurasi prediksi harga karet sehingga dapat dijadikan dasar pengambilan keputusan bagi petani, pelaku industri, dan pembuat kebijakan.

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini sebagai berikut:

1. Data yang digunakan dalam penelitian ini merupakan data harga karet global (*Agricultural Raw Materials - Rubber*) yang diperoleh dari situs *IndexMundi* (<https://www.indexmundi.com/>). Rentang waktu data yang digunakan mencakup periode Januari tahun 2000 hingga Desember 2020 sebanyak 252 baris data.
2. Evaluasi performa model prediksi dilakukan menggunakan metrik regresi, yaitu *Root Mean Square Error* (RMSE) karena metrik ini menunjukkan besarnya kesalahan prediksi dalam satuan harga yang sebenarnya.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk mengukur kinerja metode *Support Vector Regression* (SVR) dengan kernel *Radial Basis Function* dan algoritma *Grid Search* untuk memprediksi harga karet.

1.5 Manfaat Penelitian

Berikut manfaat dari penelitian ini:

1. Memberikan referensi dan implementasi praktis penggunaan metode *Support Vector Regression* (SVR) untuk memprediksi harga komoditas karet.
2. Hasil penelitian dapat membantu perencanaan produksi dan pengambilan keputusan bagi pelaku industri karet.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Kajian terhadap penelitian-penelitian sebelumnya berperan penting dalam memahami perkembangan metode prediksi (*forecasting*), terutama yang berkaitan dengan penerapan *Support Vector Regression* (SVR) pada data deret waktu di sektor ekonomi dan komoditas. Dengan menelaah berbagai studi terdahulu, dapat diidentifikasi karakteristik pendekatan yang dipakai, tingkat akurasi yang berhasil dicapai, serta keunggulan dan kelemahan masing-masing metode. Tinjauan ini sekaligus menjadi landasan konseptual bagi penelitian ini dalam mengaplikasikan SVR untuk meramalkan harga karet, yang memiliki pola fluktuatif dan cenderung tidak linear (Anamisa et al., 2025).

Penerapan SVR pada data harga saham, sebagaimana dibahas oleh Atika Mahgfirah et al. (2025), menunjukkan bahwa pemilihan parameter dan kernel yang tepat sangat menentukan kinerja model. Melalui pendekatan *Grid Search Cross-Validation*, penelitian tersebut menemukan bahwa kernel linear dengan parameter $C=100$ dan $\epsilon=0.01$ mampu memberikan performa terbaik dengan RMSE sebesar 0,0583 dan $R^2=0,99$. Hasil ini menegaskan bahwa SVR efektif dalam menangani data finansial yang memiliki dinamika cepat dan *volatil*. Efektivitas SVR juga tampak pada studi mengenai harga *Crude Palm Oil* (CPO) (Bagaskara et al., 2024). Dengan menggunakan kernel linear serta optimasi *hyperparameter* berbasis *Grid Search*, nilai MAPE sebesar 2,75% dan $R^2=0,84$ berhasil dicapai, menunjukkan

bahwa model dapat mengikuti pola fluktuatif harga komoditas dengan cukup akurat. Temuan tersebut sekaligus memperkuat posisi SVR sebagai metode yang adaptif terhadap variasi pola data deret waktu.

Penelitian lain yang berbasis metode *Autoregressive Integrated Moving Average* (ARIMA) masih digunakan, studi Fauzani & Rahmi (2023), menunjukkan bahwa model ARIMA (1,1,2) menghasilkan proyeksi harga karet yang relatif stabil untuk jangka pendek. Meskipun demikian, karakter data karet yang cenderung fluktuatif mengungkapkan keterbatasan ARIMA dalam menangkap pola nonlinier dan pengaruh eksternal yang kompleks. Pendekatan berbasis jaringan saraf tiruan turut memberikan perspektif lain Firdaus et al. (2023) melalui penggunaan model *Long Short-Term Memory* (LSTM) berhasil mencapai nilai MAPE di bawah 1,1%, menunjukkan kemampuan model dalam mengidentifikasi pola jangka panjang. Meskipun performanya baik, metode ini relatif membutuhkan data lebih besar dan struktur model yang lebih kompleks.

Kajian lain yang relevan adalah penelitian Isnaeni et al. (2022), yang menggunakan SVR dengan kernel *Radial Basis Function* (RBF) untuk memprediksi tingkat inflasi. Dengan parameter optimal $\epsilon=0,1$, $C=1$, dan $\gamma=3$ yang diperoleh melalui *Grid Search*, model mampu mencapai RMSE sebesar 0,0020. Hasil tersebut menunjukkan bahwa kernel RBF efektif untuk data nonlinier, sekaligus membuka peluang penerapannya pada komoditas lain yang memiliki pola serupa.

Sejumlah penelitian yang relevan telah dilakukan sebelumnya dengan berbagai metode menunjukkan bahwa SVR memiliki keunggulan dalam

memodelkan pola data yang kompleks dan nonlinier dibandingkan metode peramalan tradisional. Meskipun demikian, kajian yang secara khusus menerapkan SVR untuk memprediksi harga komoditas karet masih terbatas. Selain itu, variasi signifikan dalam pola harga karet menuntut metode yang mampu menangkap dinamika nonlinier secara lebih akurat. Kesenjangan inilah yang menjadi dasar penting bagi penelitian ini dalam mengembangkan model SVR teroptimasi *Grid Search* untuk menghasilkan prediksi harga karet yang lebih presisi. Ringkasan beberapa penelitian tersebut disajikan pada tabel berikut:

Tabel 2.1 Penelitian Terdahulu

No	Penulis	Judul	Metode	Hasil
1	Atika Maghfirah et al. (2025)	Analisis <i>Support Vector Regression</i> untuk Meramalkan Saham Perusahaan Dian Swastatika Sentosa (DSS) di Indonesia	<i>Support Vector Regression</i>	Model terbaik dengan kernel linear dengan parameter $C=100$ dan $\epsilon=0.01$ menghasilkan RMSE 0.0583, MAPE 10.53%, dan $R^2=0.99$.
2	Bagaskara et al. (2024)	Penerapan <i>Support Vector Regression</i> Kernel Linier dalam Meramalkan Harga CPO Indonesia	<i>Support Vector Regression</i>	Parameter terbaik $C=14$ dan $\epsilon=0.18$ menghasilkan MAPE 2.75% dan $R^2=0.84$.
3	Fauzani dan Rahmi (2023)	Penerapan Metode <i>ARIMA</i> dalam Peramalan Harga Produksi Karet di Provinsi Riau	<i>Autoregressive Integrated Moving Average</i>	Model terbaik <i>ARIMA</i> (1,1,2) mampu memproyeksikan harga produsen karet yang stabil dan cenderung meningkat.
4	Firdaus et al. (2023)	Prediksi Indeks Harga Produsen Pertanian Karet di Indonesia	<i>Long Short-Term Memory</i>	Model dengan 50 <i>neuron</i> , 25 <i>epoch</i> , dan <i>stack size</i> 10 menghasilkan RMSE 384,20

		Menggunakan Metode <i>LSTM</i>		(<i>train</i>) dan 306,01 (<i>test</i>), serta MAPE < 2%.
5	Isnaeni et al. (2022)	Analisis <i>Support Vector Regression (SVR)</i> dengan Kernel <i>Radial Basis Function (RBF)</i> untuk memprediksi laju Inflasi di Indonesia	<i>Support Vector Regression</i>	Parameter optimal $\epsilon=0.1$, $C=1$, dan $\gamma=3$ menghasilkan RMSE 0.0020.
6	Sihombing et al. (2022)	Analisis Metode Hybrid ARIMA-SVR Pada Indeks Saham Gabungan	<i>Autoregressive Integrated Moving Average, Support Vector Regression</i>	MAPE model Hybrid ARIMA-SVR untuk data training dan data testing berturut-turut sebesar 0,971% dan 0,708%.
7	Azis et al. (2023)	<i>The Support Vector Regression Method Performance Analysis in Predicting National Staple Commodity Prices</i>	<i>Support Vector Regression</i>	Nilai MSE testing 6,062, MAD testing 6,6831, MAPE testing 0,0147, dan RMSE testing 7,746.
	Usulan Penelitian			
8	Prediksi Harga Komoditas Karet Menggunakan <i>Support Vector Regression (SVR)</i>		<i>Support Vector Regression</i>	-

Berdasarkan hasil penelitian-penelitian tersebut, dapat disimpulkan bahwa metode *Support Vector Regression* menunjukkan performa yang unggul dalam berbagai konteks prediksi, baik pada data saham, inflasi, maupun harga komoditas. Metode ini mampu menangani hubungan nonlinier dan menghasilkan tingkat akurasi tinggi, terutama setelah dilakukan optimasi parameter menggunakan teknik seperti *Grid Search*.

2.2 Komoditas Karet

Karet alam merupakan salah satu komoditas perkebunan unggulan yang memiliki peranan strategis dalam perekonomian Indonesia, baik sebagai sumber pendapatan masyarakat maupun sebagai penopang sektor ekspor nonmigas. Indonesia menempati posisi sebagai produsen karet alam terbesar kedua di dunia setelah Thailand, dengan daerah penghasil utama yang tersebar di beberapa provinsi seperti Sumatera Selatan, Jambi, Riau, dan Kalimantan Barat. Sebagian besar produksi karet di Indonesia dihasilkan oleh petani kecil, sehingga komoditas ini berkontribusi signifikan terhadap peningkatan pendapatan rumah tangga di wilayah pedesaan (Khaswarina et al., 2023).

Selain menjadi sumber penghidupan jutaan petani, karet alam juga berfungsi sebagai bahan baku penting bagi berbagai industri strategis, termasuk industri otomotif, manufaktur, dan alat kesehatan. Peran tersebut menjadikan karet tidak hanya penting bagi perekonomian daerah, tetapi juga memiliki pengaruh besar terhadap kinerja perdagangan nasional. Namun, beberapa penelitian menunjukkan bahwa sebagian besar usaha tani karet rakyat masih menghadapi kendala efisiensi dalam pemanfaatan sumber daya, sehingga berimplikasi pada fluktuasi produksi karet nasional (Syarifa et al., 2025). Oleh karena itu, peningkatan efisiensi teknis dan alokatif melalui optimalisasi teknologi, kualitas bahan tanam, akses pembiayaan, serta peningkatan kapasitas petani menjadi langkah penting dalam memperkuat daya saing komoditas karet Indonesia.

Berbagai penelitian telah memberikan gambaran empiris mengenai kondisi komoditas karet di Indonesia. Studi Sri Hertina et al. (2021), menunjukkan bahwa

daya saing karet alam di Provinsi Sumatera Selatan masih tergolong rendah berdasarkan analisis keunggulan kompetitif Porter. Faktor-faktor yang berkontribusi terhadap kondisi tersebut meliputi kualitas perkebunan yang belum optimal, nilai tambah yang rendah akibat dominasi ekspor bahan baku mentah, serta rantai perdagangan yang panjang sehingga harga jual di tingkat petani menjadi rendah. Penelitian tersebut juga menyoroti keterbatasan dukungan kelembagaan daerah dalam mendorong pengembangan industri karet yang berorientasi hilirisasi.

Analisis mengenai kinerja ekspor karet Indonesia pada periode 2018-2022 yang dilakukan (Fitria et al., 2023). Memperlihatkan bahwa komoditas karet nasional masih berada pada tahap pengenalan dalam Indeks Spesialisasi Perdagangan (ISP). Tingginya nilai impor dibandingkan ekspor menunjukkan bahwa kapasitas produksi dalam negeri belum dimanfaatkan secara optimal. Selain itu, sebagian besar ekspor masih berupa bahan mentah, sehingga nilai tambah yang dihasilkan relatif rendah dan tidak mampu mendukung peningkatan kontribusi sektor karet terhadap perekonomian secara signifikan.

Kajian Sasmi et al. (2023), memberikan pemahaman lebih lanjut mengenai dinamika sosial ekonomi petani karet. Penelitian tersebut mengungkapkan bahwa pendapatan petani cenderung menurun akibat rendahnya produktivitas tenaga kerja, luas lahan yang terbatas dengan rata-rata 1,56 hektare, serta ketergantungan proses panen pada kondisi cuaca. Sistem pemasaran yang masih didominasi pedagang pengumpul turut melemahkan posisi tawar petani terhadap fluktuasi harga global. Temuan ini menunjukkan bahwa ketidakseimbangan dalam rantai distribusi menyebabkan transmisi harga yang tidak proporsional, di mana penurunan harga

dunia cepat dirasakan petani, tetapi kenaikan harga global tidak segera diikuti peningkatan harga di tingkat produsen.

2.3 Prediksi (*Forecasting*)

Prediksi (*forecasting*) merupakan proses analitis yang digunakan untuk memprediksi nilai atau kondisi di masa mendatang berdasarkan informasi yang terkandung dalam data historis. Proses ini melibatkan identifikasi pola, tren, dan fluktuasi pada deret waktu sehingga mampu menghasilkan proyeksi yang diperlukan dalam pengambilan keputusan yang lebih efektif. Dalam bidang ilmu komputer dan analitik data, peramalan deret waktu menjadi elemen penting karena memungkinkan pemodelan berbagai fenomena yang memiliki dinamika temporal (Amalia et al., 2025).

Seiring perkembangan teknologi, model *hybrid* dan model generatif mulai banyak diterapkan karena mampu mengombinasikan kelebihan berbagai pendekatan untuk mencapai tingkat akurasi dan prediksi yang lebih tinggi. Oleh sebab itu, pemilihan metode peramalan harus mempertimbangkan karakteristik data, kompleksitas sistem yang dianalisis, serta tujuan prediksi. Setiap metode memiliki karakteristik dan keunggulan tertentu yang membuatnya sesuai untuk jenis data dan kebutuhan analisis yang berbeda (Fatima & Rahimi, 2024)

Beberapa studi empiris menegaskan efektivitas metode *forecasting* dalam menghasilkan prediksi yang akurat. Analisis terhadap data historis pendaftaran mahasiswa di Universitas Indo Global Mandiri oleh Rama Samudra et al. (2024), menggunakan metode *Single Exponential Smoothing* dengan tiga nilai konstanta α (0,3; 0,6; dan 0,9). Pemilihan nilai *alpha* terbaik dilakukan berdasarkan

tingkat kesalahan (*error*) terkecil. Hasil penelitian menunjukkan bahwa *alpha* sebesar 0,9 memberikan tingkat kesalahan terendah dan kemiripan prediksi dengan data aktual mencapai 96%. Implementasi metode ini dalam sistem berbasis web mendukung pengelolaan informasi yang efisien serta proses perencanaan penerimaan mahasiswa baru.

Dalam konteks transportasi dan pariwisata, Ridla et al. (2023) menerapkan beberapa model *forecasting* untuk memprediksi jumlah wisatawan dan penumpang bandara menggunakan data deret waktu bulanan. Metode yang digunakan meliputi *Seasonal Auto Regressive Integrated Moving Average* (SARIMA), *Long Short-Term Memory* (LSTM), dan *Prophet*. Evaluasi model dilakukan dengan menggunakan *Root Mean Square Error* (RMSE) dan *Mean Square Error* (MSE). Hasil komparatif menunjukkan bahwa SARIMA memiliki performa terbaik dengan nilai RMSE dan MSE terkecil, sehingga model ini mampu menangkap pola musiman dan tren pada kedua dataset secara efektif.

Selain itu, Pangaribuan et al. (2023) mengkaji penerapan model *Autoregressive Integrated Moving Average* (ARIMA) untuk memprediksi penjualan dalam bisnis properti. Beberapa kombinasi model ARIMA diuji, yaitu ARIMA (9,1,10), ARIMA (10,1,9), ARIMA (8,1,9), ARIMA (10,1,10), dan ARIMA (12,1,12). Pemilihan model terbaik didasarkan pada nilai *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC) terendah, serta pengujian akurasi dengan RMSE, MSE, dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa ARIMA (9,1,10) memberikan performa terbaik dengan RMSE sebesar 0,281409, MSE 0,079191, dan MAPE

3,4%, sehingga model ini efektif dalam mendukung perencanaan strategis bisnis properti pada periode Juni 2017 hingga Juli 2019.

Secara keseluruhan, ketiga penelitian tersebut menunjukkan bahwa penerapan metode *forecasting* dapat memberikan hasil peramalan yang akurat apabila model yang digunakan disesuaikan dengan karakteristik data dan kebutuhan analisis. Metode seperti *Single Exponential Smoothing*, SARIMA, dan ARIMA terbukti mampu mengidentifikasi pola tren serta menghasilkan prediksi yang mendekati nilai aktual. Dengan demikian, *forecasting* memiliki peranan penting dalam mendukung pengambilan keputusan strategis di berbagai bidang, baik pendidikan, pariwisata, maupun bisnis.

2.4 Data Time Series

Data *time series* merupakan sekumpulan observasi yang dicatat secara berurutan berdasarkan waktu, sehingga memiliki pola dan ketergantungan temporal yang perlu diperhatikan dalam proses analisis maupun peramalan. Data deret waktu atau *time series* merupakan rangkaian pengamatan yang dicatat secara berurutan pada interval waktu yang sama seperti harian, mingguan, bulanan, atau tahunan. Data *time series* mencakup data temporal yang merekam fenomena dari waktu ke waktu dan memungkinkan analisis perubahan serta pemodelan prediktif berdasarkan riwayat yang ada. Data ini muncul ketika observasi dilakukan secara periodik dan menunjukkan pola-pola seperti tren maupun musiman (Fungki Wahyu & Billy Hendrik, 2023).

Dalam penelitian Najib & Nurdiati (2025), data deret waktu diartikan sebagai rentetan pengamatan terhadap satu variabel yang dicatat secara kronologis,

di mana tiap pengamatan saling berkaitan dan memberikan gambaran dinamis dari waktu ke waktu. Penelitian tersebut menyoroti bahwa dalam konteks harga saham bulanan, deret waktu ini kerap memiliki karakter non-linier, varians yang tidak konstan, serta ketergantungan historis jangka pendek maupun jangka panjang yang kompleks. Karakteristik pola yang tidak linier, dinamika yang cepat berubah, dan ketergantungan waktu yang kompleks. Analisis deret waktu dalam penelitian ini bukan sekadar mengenali tren atau musiman secara sederhana, tetapi juga memahami karakteristik temporal yang lebih kompleks yang melekat dalam data pengamatan *sekuensial*.

Perkembangan penelitian terkini menunjukkan bahwa analisis deret waktu (*time series*) menekankan pentingnya pemahaman karakteristik data dan tujuan peramalan dalam menentukan metode yang tepat. Keberhasilan analisis deret waktu sangat bergantung pada kualitas data, pemilihan fitur yang relevan, ukuran dataset, interval historis, serta kesesuaian model dengan karakteristik tugas dan tujuan peramalan, dengan evaluasi kinerja yang tepat menggunakan metrik seperti RMSE, atau MAPE. Analisis deret waktu modern mengintegrasikan pemodelan pola historis, teknik statistik, pembelajaran mesin, dan optimasi *hyperparameter* untuk menghasilkan prediksi yang andal, akurat, dan aplikatif dalam berbagai domain (Hall & Rasheed, 2025).

2.5 Pra-pemrosesan Data

Pra-pemrosesan data (*data preprocessing*) merupakan serangkaian tahapan yang dilakukan untuk mempersiapkan data sebelum digunakan dalam proses pembentukan model prediksi. Tahapan ini bertujuan untuk menghasilkan data yang

lebih terstruktur, relevan, dan sesuai dengan karakteristik algoritma yang digunakan (Juliandy et al., 2024). Dalam penelitian prediksi harga komoditas karet menggunakan *Support Vector Regression* (SVR), proses pra-pemrosesan data meliputi rekayasa fitur, pembagian data, dan normalisasi. Ketiga tahapan tersebut saling berkaitan dan dilakukan secara berurutan untuk memastikan data yang digunakan mampu mendukung proses pelatihan serta evaluasi model secara optimal.

1. Rekayasa Fitur (*feature engineering*)

Tahap pertama dalam pra-pemrosesan data adalah rekayasa fitur (*feature engineering*), yaitu proses pembentukan variabel masukan yang dapat merepresentasikan informasi penting dari data asli. Pada data deret waktu (*time series*), nilai suatu periode umumnya dipengaruhi oleh nilai pada periode sebelumnya. Oleh karena itu, informasi historis perlu ditransformasikan ke dalam bentuk fitur yang dapat dipelajari oleh model agar pola temporal yang terkandung dalam data dapat dimanfaatkan secara lebih efektif (Astiningrum et al., 2021).

Berdasarkan pertimbangan tersebut, penelitian ini menerapkan teknik *lag feature* dengan *lag* satu periode. Melalui teknik ini, nilai harga komoditas karet pada satu bulan sebelumnya digunakan sebagai variabel prediktor untuk memprediksi harga pada bulan berikutnya. Dengan kata lain, nilai pada periode $t-1$ digunakan untuk memperkirakan nilai pada periode t . Hasil dari proses rekayasa fitur ini kemudian membentuk dataset baru yang siap digunakan pada tahap berikutnya, yaitu pembagian data.

2. Pembagian Data

Setelah fitur prediktor berhasil dibentuk, tahapan selanjutnya adalah pembagian data ke dalam data latih (*training data*) dan data uji (*testing data*). Proses ini dilakukan untuk memastikan bahwa model dapat dibangun menggunakan sebagian data dan dievaluasi menggunakan data lain yang tidak terlibat dalam proses pelatihan (Azis et al., 2023). Dengan demikian, kemampuan model dalam melakukan prediksi terhadap data baru dapat diukur secara lebih objektif.

Karena penelitian ini menggunakan data deret waktu, pembagian data dilakukan dengan tetap mempertahankan urutan kronologis observasi. Pendekatan yang digunakan adalah *time series split* dengan proporsi 80:20, yaitu 80% data digunakan sebagai data latih dan 20% sisanya digunakan sebagai data uji. Pemilihan pendekatan ini bertujuan untuk menghindari penggunaan informasi dari periode mendatang dalam proses pelatihan model, sehingga hasil evaluasi yang diperoleh dapat menggambarkan performa model secara lebih realistis. Setelah data dipisahkan ke dalam dua kelompok tersebut, tahap berikutnya adalah melakukan normalisasi untuk menyamakan rentang nilai data.

3. Normalisasi

Normalisasi merupakan proses transformasi data yang dilakukan setelah pembagian data untuk mengurangi pengaruh perbedaan skala nilai antarvariabel. Tahapan ini menjadi penting karena algoritma *Support Vector Regression* bekerja berdasarkan perhitungan jarak dan proses optimasi yang

sensitif terhadap rentang nilai data (Yusuf Andrika & Rahardi, 2025). Apabila terdapat perbedaan skala yang terlalu besar, variabel dengan rentang nilai lebih tinggi dapat mendominasi proses pembelajaran dan memengaruhi kualitas model yang dihasilkan.

Dalam penelitian ini, normalisasi dilakukan menggunakan metode *Min-Max Scaler* yang mentransformasikan data ke dalam rentang nilai 0 hingga 1. Proses tersebut dilakukan dengan memanfaatkan nilai minimum dan maksimum pada data sehingga setiap observasi memiliki skala yang seragam tanpa mengubah pola distribusi aslinya. Melalui penerapan normalisasi, data yang telah melalui proses rekayasa fitur dan pembagian data menjadi lebih sesuai untuk digunakan dalam pelatihan model SVR, sehingga proses pembelajaran dapat berlangsung secara lebih stabil dan menghasilkan performa prediksi yang lebih baik.

2.6 Support Vector Regression (SVR)

Support Vector Regression (SVR) merupakan turunan dari algoritma *Support Vector Machine* (SVM) yang difungsikan untuk meramalkan nilai bersifat kontinu. Metode ini dirancang guna menangani persoalan regresi, seperti prediksi angka numerik berdasarkan pola dari data yang tersedia. SVR berupaya menemukan fungsi yang mampu memprediksi nilai target dengan menekan kesalahan prediksi seminimal mungkin. Untuk mencapai hal tersebut, SVR memanfaatkan *support vectors*, yakni titik-titik data penting yang menentukan lokasi serta bentuk dari fungsi prediksi (Nathansyah, 2025).

Untuk memastikan model tidak sekadar cocok dengan data latih, tetapi juga mampu melakukan prediksi secara andal, SVR memanfaatkan margin, yaitu jarak antara fungsi prediksi dengan titik data terdekat (Hermawan et al., 2022). Dalam konteks regresi, fungsi prediksi dari SVR dapat dinyatakan sebagai:

$$f(x_i) = \sum_{i=1}^m (a_i - a_i^*) K(x_i, x_i) + b \quad (2.1)$$

Keterangan:

a_i, a_i^* = Pengali *Lagrange*
 $K(x_i, x_i)$ = Fungsi kernel
 b = Konstanta

Pemilihan fungsi kernel merupakan faktor krusial yang mempengaruhi performa model *Support Vector Regression*. Dalam penelitian ini, digunakan fungsi kernel *Radial Basis Function* (RBF) karena kemampuannya yang unggul dalam menangani pola data non-linear secara efektif (Ishlah et al., 2023). Kernel RBF didefinisikan sebagai:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2.2)$$

Keterangan:

x_i, x_j = Vektor data
 γ = Parameter kernel
 $\|x_i - x_j\|^2$ = Jarak kuadrat antara dua titik

Keunggulan kernel RBF dalam konteks prediksi data *time series* telah dibuktikan melalui penelitian. Purwoko et al., (2023) dalam penelitiannya mengenai prediksi harga ekspor non migas di Indonesia membuktikan bahwa model *Support Vector Regression* dengan kernel *Radial Basis Function* menghasilkan akurasi yang jauh lebih baik dibandingkan metode estimator deret *Fourier*, dengan

nilai MAPE masing-masing sebesar 9,29% dan 15,26%, yang mengindikasikan kemampuan kernel RBF dalam mengakomodasi fluktuasi data non-linear seperti pandemi COVID-19.

2.7 Parameter *Support Vector Regression*

Pada *Support Vector Regression* (SVR) dengan kernel *Radial Basis Function* (RBF), terdapat tiga parameter utama yang memengaruhi performa model, yaitu parameter C , ε (*epsilon*), dan γ (*gamma*). Ketiga parameter tersebut berperan dalam mengatur kompleksitas model, toleransi kesalahan, serta pengaruh data terhadap fungsi regresi (Priyono et al., 2025).

1. *Cost* (C)

Parameter C berperan sebagai regularisasi yang mengatur keseimbangan antara tingkat kerumitan model dan toleransi terhadap kesalahan prediksi. Apabila nilai C besar, penalti atas kesalahan semakin tinggi, sehingga model cenderung menyesuaikan data pelatihan dengan sangat ketat. Sebaliknya, nilai C yang kecil memberikan toleransi kesalahan lebih longgar, menjadikan model lebih sederhana dan kemampuannya dalam generalisasi menjadi lebih baik.

2. *Epsilon* (ε)

Parameter ε menetapkan batas toleransi kesalahan melalui fungsi *loss* yang *insensitive* terhadap *epsilon* pada SVR. Selama proses pelatihan, kesalahan prediksi yang masih berada dalam batas ε tidak akan dikenai sanksi. Nilai ε yang besar menghasilkan model yang lebih sederhana karena

makin banyak kesalahan yang diabaikan, sementara nilai ϵ yang kecil menjadikan model lebih peka terhadap setiap perubahan pada data.

3. *Gamma* (γ)

Parameter γ merupakan parameter pada kernel *Radial Basis Function* yang mengatur luas pengaruh setiap data pelatihan terhadap pembentukan fungsi regresi. Nilai γ yang besar menyebabkan pengaruh data menjadi lebih sempit sehingga model dapat menangkap pola secara lebih detail, tetapi berpotensi mengalami *overfitting*. Sebaliknya, nilai γ yang kecil menghasilkan pengaruh yang lebih luas sehingga model menjadi lebih halus dan memiliki kemampuan generalisasi yang lebih baik.

2.8 Algoritma *Grid Search*

Grid search merupakan pendekatan pencarian *hyperparameter* yang dilaksanakan secara terstruktur dengan menguji seluruh kombinasi nilai parameter yang telah ditetapkan sebelumnya. Metode ini banyak digunakan pada *Support Vector Regression* (SVR) karena kinerja model sangat ditentukan oleh pemilihan *hyperparameter* seperti parameter regularisasi C , parameter toleransi error ϵ , serta parameter kernel γ . Apabila *hyperparameter* tidak dipilih secara tepat, model dapat mengalami *overfitting* atau *underfitting*, yaitu gagal menangkap pola data secara memadai (Safira et al., 2023).

Dalam penelitian ini, *Grid Search* diterapkan untuk menemukan parameter optimal pada metode *Support Vector Regression* (SVR). Proses ini dilakukan melalui mekanisme parameter tuning guna menentukan konfigurasi *hyperparameter* terbaik dari setiap nilai parameter, sehingga kinerja model dapat

dimaksimalkan secara optimal (Medyanti et al., 2024). Adapun langkah-langkah penerapan *Grid Search* pada penelitian ini adalah sebagai berikut:

1. Menentukan rentang nilai *Hyperparameter*, misalnya $C = [1, 10, 100]$, $\varepsilon = [0.01, 0.1, 0.2]$, dan $\gamma = [0.01, 0.1, 0.2]$.
2. Menentukan skema evaluasi, misalnya *5-fold cross-validation*.
3. Menentukan parameter terbaik berdasarkan RMSE terendah.
4. Melatih model SVR dengan parameter terbaik pada seluruh data.
5. Melakukan prediksi menggunakan model dengan parameter terbaik.

2.9 Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) termasuk salah satu metrik evaluasi yang paling lazim digunakan untuk mengukur tingkat kesalahan dalam model regresi. RMSE diperoleh dengan menghitung rata-rata dari kuadrat selisih antara nilai aktual dan nilai prediksi, kemudian diakarkan. Karena menggunakan perhitungan kuadrat, RMSE memberikan hukuman yang lebih berat terhadap kesalahan prediksi yang memiliki deviasi besar (*large error*).

Semakin kecil nilai RMSE yang dihasilkan, semakin baik performa prediksi model, karena rata-rata kesalahan prediksi yang diperoleh semakin rendah (Nurholipah et al., 2024). Dalam penelitian ini, RMSE dipakai sebagai tolok ukur untuk menilai akurasi model Support Vector Regression (SVR) dalam meramalkan harga karet. Penggunaan RMSE sebagai metrik evaluasi bertujuan memastikan bahwa model tidak hanya mampu menghasilkan prediksi yang mendekati nilai nyata, tetapi juga dapat menekan kesalahan dengan deviasi besar pada hasil prediksi. RMSE didefinisikan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.3)$$

Keterangan:

y_i = Nilai aktual ke-i

$\hat{y}_i$ = Nilai prediksi ke-i


n = Jumlah observasi

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Desain Penelitian

Desain penelitian ini bertujuan untuk memberikan kerangka sistematis dalam pelaksanaan penelitian. Desain penelitian ini disusun sedemikian rupa agar alur penelitian dapat diikuti secara logis dan transparan, sehingga setiap tahapan, mulai dari pengumpulan data, pemodelan, hingga evaluasi hasil, dapat dilaksanakan secara terstruktur.



Gambar 3.1 Desain Penelitian

3.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data yang diperoleh dari situs *IndexMundi* (<https://www.indexmundi.com/>), khususnya pada bagian *Agricultural Raw Materials - Rubber*. Dataset ini berisi informasi mengenai harga karet alam (*natural rubber*) global dalam satuan *US Dollar* per kilogram (*USD/kg*) dengan periode pengamatan tahun 2000 hingga 2020 sebanyak 252 data. Data

tersebut dipilih karena memiliki cakupan waktu yang panjang dan bersumber dari lembaga ekonomi internasional yang terpercaya, sehingga dapat menggambarkan dinamika harga karet secara global secara komprehensif.

IndexMundi mengompilasi data harga karet dari berbagai sumber resmi, termasuk bursa komoditas internasional dan laporan lembaga ekonomi dunia, sehingga dataset ini memiliki tingkat reliabilitas yang tinggi untuk digunakan dalam penelitian berbasis analisis deret waktu (*time series*). Data diakses dan diunduh pada tanggal 03 November 2025 untuk memastikan transparansi dan reproduktifitas penelitian.



Gambar 3.2 Grafik Harga Karet Tahun 2000-2020
(*IndexMundi*)

3.2.1 Analisis Deskriptif

Berdasarkan analisis statistik deskriptif yang dilakukan terhadap dataset harga karet periode Januari 2000 hingga Desember 2020, diperoleh karakteristik fundamental seperti yang disajikan pada Tabel 3.1 berikut:

Tabel 3.1 Analisis Dekriptif

Data Harga Karet Bulanan				
Min	Maks	Rata-rata	Varian	Std Dev
0.49	6.26	1.97	1.13627	1.07


Berdasarkan Tabel 3.1, harga karet alam dalam periode 21 tahun tersebut memiliki nilai rata-rata sebesar USD 1.97 per kilogram. Nilai minimum harga tercatat sebesar USD 0.49 per kg, sedangkan nilai maksimum mencapai USD 6.26 per kg, yang menghasilkan rentang sebesar USD 5.77 per kg. Besarnya rentang ini mengindikasikan fluktuasi harga yang signifikan. Lebih lanjut, standar deviasi yang cukup tinggi, yaitu USD 1.07, serta varians sebesar USD 1.14, mengonfirmasi bahwa sebaran data harga cenderung luas dan memiliki volatilitas yang tinggi. Hal ini menunjukkan ketidakstabilan harga karet alam dalam jangka waktu yang panjang, yang dapat dipengaruhi oleh berbagai faktor fundamental pasar global.

Karakteristik data harga karet yang volatil mengindikasikan pola non-linear, sehingga kernel *Radial Basis Function* (RBF) dipilih karena kemampuannya menangkap hubungan kompleks antar variabel. Namun, performa kernel ini sangat bergantung pada penentuan nilai parameter, kesalahan pemilihan dapat menyebabkan *overfitting* atau *underfitting*. Oleh karena itu, *Grid Search* digunakan untuk mencari kombinasi parameter terbaik guna menghasilkan model dengan akurasi prediksi yang optimal.

3.3 Perancangan Desain Sistem

Perancangan desain sistem merupakan tahap penting dalam penelitian ini yang bertujuan untuk menjelaskan alur kerja sistem prediksi harga karet secara terstruktur dan sistematis (Yan et al., 2022). Desain sistem memberikan panduan

visual dan konseptual tentang bagaimana data dikumpulkan, diproses, dianalisis, serta diinterpretasikan menggunakan metode *Support Vector Regression*. Dengan adanya desain sistem, setiap tahapan penelitian dapat dilakukan secara konsisten dan terstruktur.



Gambar 3.3 Desain Sistem

Pada tahap input, data harga karet dunia digunakan sebagai sumber utama dalam proses pemodelan. Data tersebut kemudian memasuki tahap proses yang diawali dengan pra-pemrosesan untuk membersihkan data, dilanjutkan dengan *feature engineering* guna membentuk variabel-variabel yang relevan, serta normalisasi target dan fitur agar seluruh data berada pada skala yang seragam dan mendukung kinerja model secara optimal.

Setelah data siap, dilakukan pembagian data menjadi data latih dan data uji. Selanjutnya, pada tahap pemodelan, dilakukan inisialisasi parameter awal untuk algoritma *Support Vector Regression* (SVR), kemudian dilanjutkan dengan inisialisasi kernel *Radial Basis Function* (RBF) sebagai fungsi kernel yang akan digunakan dalam proses pemodelan. Untuk mendapatkan kombinasi parameter terbaik, dilakukan optimasi *hyperparameter* menggunakan metode *Grid Search* dengan mencoba berbagai nilai parameter pada kernel RBF. Model SVR kemudian diimplementasikan dengan parameter hasil optimasi, dan diikuti dengan pengujian model menggunakan data uji.

Tahap akhir adalah hasil pengujian, di mana performa model dievaluasi menggunakan metrik *Root Mean Square Error* (RMSE) untuk mengukur tingkat akurasi hasil prediksi.

3.4 Optimasi Algoritma *Grid Search*


Optimasi *hyperparameter* dalam penelitian ini dilakukan menggunakan algoritma *Grid Search* untuk memperoleh konfigurasi terbaik pada model *Support Vector Regression* (SVR). Proses evaluasi dilakukan menggunakan *5-fold cross-validation* untuk menilai kinerja model pada berbagai subset data dan mengurangi bias evaluasi. Dari seluruh kombinasi *hyperparameter* yang diuji, dipilih konfigurasi yang menghasilkan nilai *Root Mean Squared Error* (RMSE) terendah sebagai parameter terbaik (Fajri & Primajaya, 2023).

Setelah parameter terbaik diperoleh, model SVR dilatih ulang menggunakan seluruh data latih dan diterapkan untuk memprediksi harga karet. Pendekatan ini memastikan prediksi yang dihasilkan lebih akurat dan stabil, sekaligus

meningkatkan kemampuan generalisasi model terhadap data baru. Penerapan *Grid Search* menjadi langkah penting untuk memperoleh model prediksi harga karet yang baik (Putra et al., 2024).

3.5 Implementasi *Support Vector Regression*

Implementasi algoritma *Support Vector Regression* (SVR) pada penelitian ini dilakukan untuk memprediksi harga karet. Gambaran umum algoritma SVR adalah melakukan percobaan untuk menemukan nilai terbaik dalam bentuk garis antara garis *hyperplane* dan garis batas (*boundary line*), seperti yang ditunjukkan pada Gambar 3.4.



Gambar 3.4 *Hyperplane*

Pada *Support Vector Regression* (SVR), *hyperplane* berfungsi sebagai representasi linear terbaik yang memodelkan hubungan antara variabel *input* dan *output* dalam ruang fitur. Di sekitar *hyperplane* tersebut terdapat *boundary lines* yang membentuk batas toleransi kesalahan atau *margin ϵ* (*epsilon-insensitive zone*). Setiap titik data yang berada di dalam margin ini dianggap memiliki kesalahan yang masih dapat diterima, sedangkan data yang berada di luar margin dikategorikan sebagai penyimpangan yang lebih besar. Untuk mengakomodasi penyimpangan tersebut, SVR menggunakan variabel *slack* yang menggambarkan besarnya deviasi

data terhadap batas *epsilon*, sehingga model tetap dapat bekerja meskipun menghadapi data yang tidak sepenuhnya berada dalam *margin* toleransi (Pradasyah & Baita, 2025).

3.5.1 Persiapan Data

Data yang digunakan adalah data harga karet periode Januari hingga Desember tahun 2000. Data diambil dari situs *IndexMundi* yang ditampilkan pada Tabel 3.2

Tabel 3.2 Harga Karet Dunia tahun 2000

Tahun	Bulan	Harga Karet
2000	Januari	0.64
	Februari	0.74
	Maret	0.68
	April	0.70
	Mei	0.69
	Juni	0.67
	Juli	0.65
	Agustus	0.66
	September	0.66
	Oktober	0.66
	November	0.63
	Desember	0.62

Data harga karet tersebut selanjutnya diproses melalui beberapa tahapan untuk mempersiapkannya dalam pemodelan prediksi. Setiap tahapan akan dijelaskan secara rinci pada sub-bab berikutnya.

3.5.2 Feature Engineering

Pada tahap pembentukan fitur, dilakukan proses penurunan variabel dari data harga karet untuk membantu model dalam mengenali pola perubahan harga. Fitur

yang digunakan adalah *Lag feature*. Fitur *Lag* menggambarkan harga satu bulan sebelumnya.

Tabel 3.3 Lag feature

Tahun	Bulan	Harga Karet	Lag Feature
2000	Januari	0.64	-
	Februari	0.74	0.64
	Maret	0.68	0.74
	April	0.70	0.68
	Mei	0.69	0.70
	Juni	0.67	0.69
	Juli	0.65	0.67
	Agustus	0.66	0.65
	September	0.66	0.66
	Oktober	0.66	0.66
	November	0.63	0.66
	Desember	0.62	0.63

Bulan Januari tidak memiliki fitur *lag* dikarenakan data yang digunakan adalah tahun 2000, yang merupakan tahun pertama sehingga tidak memiliki *lag feature* dari bulan sebelumnya.

3.5.3 Normalisasi

Normalisasi dilakukan untuk menyesuaikan skala semua fitur dan target pada rentang yang seragam. Dalam penelitian ini, normalisasi dilakukan menggunakan metode *Min-Max Scaling*, yang mengubah nilai setiap fitur ke dalam rentang 0 hingga 1 (Ishlah et al., 2023). *Min-Max Scaling* Dapat didefinisikan sebagai berikut:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.1)$$

$$X' = \frac{0.69 - 0.62}{0.74 - 0.62}$$

$$X' = \frac{0.07}{0.12}$$

$$X' = 0.583$$

Tabel 3.4 Data setelah dinormalisasi

Bulan	Harga Aktual (X)	Lag (Y)	Normalisasi X	Normalisasi Y
1	0.64	0	0.166667	0.000000
2	0.74	0.64	1.000000	0.864865
3	0.68	0.74	0.500000	1.000000
4	0.70	0.68	0.666667	0.918919
5	0.69	0.70	0.583333	0.945946
6	0.67	0.69	0.416667	0.932432
7	0.65	0.67	0.250000	0.905405
8	0.66	0.65	0.333333	0.878378
9	0.66	0.66	0.333333	0.891892
10	0.66	0.66	0.333333	0.891892
11	0.63	0.66	0.083333	0.891892
12	0.62	0.63	0.000000	0.851351

3.5.4 Perhitungan dengan kernel *Radial Basis Function*

Pada tahap ini dilakukan perhitungan nilai kernel antar setiap pasangan titik data menggunakan fungsi kernel *Radial Basis Function* (RBF) sebagaimana dirumuskan pada persamaan (2.2). Nilai $\|x_i - x_j\|^2$ merupakan jarak *Euclidean* kuadrat antara dua titik data, sedangkan parameter γ mengontrol tingkat kelengkungan fungsi kernel. Pada penelitian ini, nilai γ ditetapkan sebesar 0.01 sesuai konfigurasi awal yang telah ditentukan.

Perhitungan dilakukan untuk seluruh pasangan titik data sehingga dihasilkan sebuah matriks kernel berukuran 12×12 . Matriks ini digunakan sebagai komponen utama dalam proses optimasi SVR pada tahap selanjutnya. Adapun hasil perhitungan nilai kernel ditunjukkan sebagai berikut:

$$K = \begin{bmatrix} 1 & 0.992548 & 0.990050 & 0.991591 & \dots & 0.992778 \\ 0.992548 & 1 & 0.999817 & 0.999971 & \dots & 0.999998 \\ 0.990050 & 0.999817 & 1 & 0.999934 & \dots & 0.999779 \\ 0.991591 & 0.999971 & 0.999934 & 1 & \dots & 0.999954 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0.992778 & 0.999998 & 0.999779 & 0.999954 & \dots & 1 \end{bmatrix}$$

3.5.5 Optimasi *Hyperparameter*

Konfigurasi *hyperparameter* yang digunakan dalam proses pelatihan model *Support Vector Regression* (SVR). Untuk perhitungan awal, nilai *hyperparameter* ditetapkan pada $C = 1$, $\varepsilon = 0.1$, dan $\gamma = 0.01$. Nilai ini digunakan sebagai parameter *default* dalam penyelesaian *Quadratic Programming* untuk memperoleh parameter dual SVR, yaitu alpha (α) dan bias (b).

Perhitungan dilakukan menggunakan *Python* secara iteratif hingga parameter α dan b mencapai kondisi konvergen. Hasil akhir perhitungan nilai alpha dan bias disajikan pada Tabel 3.5.

Tabel 3.5 Nilai Alpha setiap titik data

Bulan	Alpha	Alpha*
1	0	1
2	1	0
3	1	0
4	1	0
5	1	0
6	1	0
7	0	1
8	0	0
9	0	1
10	0	0
11	0	1
12	0	1

bias = 0.335569

4.1.1 Menghitung Prediksi

Langkah selanjutnya adalah melakukan prediksi, dengan nilai alpha yang sudah didapatkan, berikut perhitungan menggunakan rumus prediksi pada bulan Mei dengan rumus persamaan (2.1):

$$f(x_i) = \sum_{i=1}^m (a_i - a_i^*)K(x_i, x_i) + b$$

$$f(x_{MEI}) = 0.00896 + b$$

$$f(x_{MEI}) = 0.00896 + 0.33556$$

$$f(x_{MEI}) = 0.34453$$

Setelah ditemukan hasil dari prediksi pada bulan Mei untuk menganalisis hasil dibutuhkan *denormalisasi* agar data kembali ke skala awal.

$$X' = f(x) * (X_{max} - X_{min}) + X_{min} \quad (3.2)$$

$$X' = 0.34453 * (0.74 - 0.62) + 0.62$$

$$X' = (0.34453 * 0.12) + 0.62$$

$$X' = 0.66134$$

Berikut adalah hasil prediksi menggunakan metode SVR dari 12 data awal bulan Januari hingga Desember.

Tabel 3.6 Data hasil prediksi

Bulan	Data Aktual	Data Prediksi
1	0.64	0.658811
2	0.74	0.661128
3	0.68	0.661489
4	0.70	0.661272
5	0.69	0.661344
6	0.67	0.661308
7	0.65	0.661236

8	0.66	0.661164
9	0.66	0.661200
10	0.66	0.661200
11	0.63	0.661200
12	0.62	0.661092

4.1.2 Menghitung RMSE

Setelah menghitung nilai prediksi, langkah selanjutnya adalah mencari nilai RMSE dengan persamaan (2.3), perhitungannya sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

$$RMSE = \sqrt{\frac{1}{12} (0.012106)}$$

$$RMSE = \sqrt{\frac{0.012106}{12}}$$

$$RMSE = \sqrt{0.001008}$$

$$RMSE = 0.031763$$

3.6 Skenario Pengujian

Pengujian dilakukan untuk memastikan validitas hasil prediksi yang dihasilkan oleh model. Dalam penelitian ini, pengujian diterapkan dengan menggunakan kombinasi antar parameter pada *Support Vector Regression* (SVR), yaitu C , ϵ , dan γ . Untuk memprediksi harga karet, adapun kombinasi parameter yang akan digunakan dapat dilihat pada tabel 3.7.

Tabel 3.7 Kombinasi Parameter

Parameter	
Kernel	RBF
Nilai C	1, 10, 100
Nilai epsilon	0.01, 0.1, 0.2
Nilai gamma	0.01, 0.1, 0.2

Parameter yang digunakan dalam penelitian ini mencakup kernel RBF dengan kombinasi nilai C (1, 10, 100), epsilon (0.01, 0.1, 0.2), dan gamma (0.01, 0.1, 0.2). Dari kombinasi ketiga *hyperparameter* tersebut, terbentuk total 27 model SVR (*Support Vector Regression*) yang masing-masing model akan diuji menggunakan data yang telah disiapkan. Evaluasi kinerja dilakukan dengan menggunakan metrik *Root Mean Squared Error* (RMSE), dan model dengan nilai RMSE paling rendah akan dipilih sebagai model terbaik karena dianggap memiliki akurasi prediksi tertinggi.

BAB IV

HASIL DAN PEMBAHASAN

4.2 Hasil

Uji coba penelitian dilakukan untuk mengidentifikasi tingkat kesalahan dari metode *Support Vector Regression* dengan kernel *Radial Basis Function* dan *Grid Search* sebagai optimasi dalam memprediksi harga karet. Tingkat kesalahan prediksi pada harga karet diukur dengan perhitungan *Root Mean Squared Error* (RMSE).

4.2.1 Input Data

Pada tahap awal, data harga komoditas karet dimuat ke dalam sistem untuk digunakan dalam proses penelitian. Dataset yang digunakan berjumlah 252 data yang mencakup periode Januari 2000 hingga Desember 2020 dengan frekuensi pencatatan bulanan. Setiap data merepresentasikan harga komoditas karet dalam satuan USD/kg, data tersebut selanjutnya digunakan dalam proses pra-pemrosesan.

Tabel 4.1 Data Harga Karet

Bulan	Harga
2000-01-01	0.64
2000-02-01	0.74
2000-03-01	0.68
.....	
2020-10-01	2.19
2020-11-01	2.30
2020-12-01	2.33

4.1.2 Pra-pemrosesan Data

Setelah data berhasil diinputkan, langkah selanjutnya adalah melakukan pra-pemrosesan data. Tahap ini bertujuan untuk menyiapkan data agar sesuai dengan kebutuhan metode *Support Vector Regression* sebelum proses pelatihan model dilaksanakan. Pra-pemrosesan data dalam penelitian ini mencakup tiga tahapan utama, yaitu rekayasa fitur, pembagian data, dan normalisasi data. Ketiga tahapan tersebut diuraikan secara rinci sebagai berikut.

1. Rekayasa Fitur

Tahap pertama dalam pra-pemrosesan data adalah rekayasa fitur dengan menggunakan fitur *lag-1*. Pada tahap ini, nilai harga karet pada periode sebelumnya digunakan sebagai variabel masukan (fitur) untuk memprediksi nilai harga pada periode saat ini. Pembentukan fitur *lag-1* dilakukan karena data yang digunakan merupakan data deret waktu (*time series*), sehingga informasi dari periode sebelumnya dianggap memiliki pengaruh yang signifikan terhadap nilai pada periode berikutnya.

Tabel 4.2 *Lag Feature*

Bulan	Harga	Harga Lag-1
2000-02-01	0.74	0.64
2000-03-01	0.68	0.74
2000-04-01	0.70	0.68
.....		
2020-10-01	2.19	1.86
2020-11-01	2.30	2.19
2020-12-01	2.33	2.30

Setelah proses pembentukan fitur *lag-1* dilakukan, jumlah data berkurang dari 252 menjadi 251 data. Hal ini disebabkan karena data

pada baris pertama (Januari 2000) tidak memiliki nilai sebelumnya yang dapat digunakan sebagai fitur, sehingga data tersebut tidak dapat diikutsertakan dalam proses pemodelan.

2. Pembagian Data

Setelah rekayasa fitur selesai dilakukan, tahap berikutnya adalah pembagian data menjadi data latih (*training data*) dan data uji (*testing data*). Pembagian data dilakukan menggunakan pendekatan *time series split* dengan proporsi 80:20 berdasarkan urutan waktu untuk mempertahankan karakteristik kronologis data. Sebanyak 215 data pada periode Februari 2000 hingga Desember 2017 digunakan sebagai data latih, sedangkan 36 data pada periode Januari 2018 hingga Desember 2020 digunakan sebagai data uji.

Tabel 4.3 Pembagian Data

Jumlah Data Latih	Jumlah Data Uji
215	36

3. Normalisasi Data

Setelah pembagian data selesai dilakukan, tahap selanjutnya adalah normalisasi data menggunakan metode *Min-Max Scaler*. Normalisasi diterapkan secara terpisah pada variabel fitur dan variabel target dengan mengubah rentang nilai data ke dalam skala $[0,1]$. Proses ini dilakukan untuk mengurangi perbedaan rentang nilai antar variabel sehingga seluruh data berada pada skala yang seragam.

Tabel 4.4 Normalisasi *Min-Max Scaler*

Y'	Y'	X	X'
0.64	0.025997	0.74	0.043328
0.74	0.043328	0.68	0.032929
0.68	0.032929	0.70	0.036395
.....			
2.21	0.298094	2.10	0.279029
2.10	0.279029	1.72	0.213172
1.72	0.213172	1.75	0.218371

4.1.3 Pelatihan Model Support Vector Regression

Setelah tahap pra-pemrosesan data selesai dilakukan, langkah berikutnya adalah pelatihan model *Support Vector Regression* (SVR). Pada penelitian ini, pelatihan model dilakukan dalam dua skenario, yaitu model tanpa optimasi *hyperparameter* dan model dengan optimasi *hyperparameter* menggunakan metode *Grid Search*. Kedua skenario tersebut digunakan untuk mengetahui pengaruh optimasi *hyperparameter* terhadap kinerja model dalam memprediksi harga komoditas karet.

Pada skenario pertama, model *Support Vector Regression* (SVR) dibangun tanpa melalui proses optimasi *hyperparameter*. Model menggunakan nilai parameter bawaan (*default*) dari *library Scikit-learn* dengan kernel *Radial Basis Function* (RBF). Parameter yang digunakan pada model tanpa optimasi disajikan pada Tabel 4.5.

Tabel 4.5 Parameter Model Tanpa Optimasi

Parameter	Nilai
Kernel	Radial Basis Function (RBF)
C	1
Epsilon	0.1
Gamma	0.1

Model kemudian dilatih menggunakan data latih yang telah disiapkan pada tahap sebelumnya. Pelatihan ini bertujuan untuk membentuk model dasar (*baseline model*) yang nantinya digunakan sebagai pembanding terhadap model yang telah melalui proses optimasi *hyperparameter*.

Proses pembelajaran model berusaha menemukan fungsi *hyperplane* yang meminimalkan *error* dengan mempertimbangkan parameter *C*, *epsilon*, dan *gamma* yang telah ditentukan. Selama proses pelatihan, model menghitung nilai prediksi untuk setiap data latih, kemudian membandingkannya dengan nilai aktual untuk menghasilkan nilai *error*. *Error* tersebut dihitung dalam bentuk selisih aktual dan prediksi, nilai absolut *error*, serta kuadrat *error* yang digunakan dalam perhitungan RMSE. Hasil proses pembelajaran pada data latih disajikan pada Tabel 4.6.


Tabel 4.6 Hasil *Training* Model Tanpa Optimasi

Actual Output	Predicted Output	Error	Error	Error ²
0.74	1.061360	-0.321360	0.321360	0.103273
0.68	1.088035	-0.408035	0.408035	0.166493
0.70	1.069075	-0.369075	0.369075	0.136216
0.69	1.074434	-0.384434	0.384434	0.147790
0.67	1.071632	-0.401632	0.401632	0.161308
.....				
1.66	1.729600	-0.069600	0.069600	0.004844
1.87	1.780748	0.089252	0.089252	0.007966
2.23	1.867069	0.362931	0.362931	0.131719
2.56	1.991813	0.568187	0.568187	0.322837
2.71	2.245819	0.464181	0.464181	0.215464
MSE			0.091389	
RMSE			0.302307	
R²			0.928987	

Berdasarkan Tabel 4.6, terlihat bahwa model menghasilkan nilai prediksi yang bervariasi dengan tingkat error yang berbeda-beda pada setiap data latih. Error terbesar terjadi pada data dengan nilai aktual 2.56 dengan selisih 0.568187,

sedangkan error terkecil terjadi pada data dengan nilai aktual 1.66 dengan selisih 0.069600. Hal ini menunjukkan bahwa model belum sepenuhnya mampu menangkap pola data secara optimal pada beberapa titik tertentu.

Untuk memvisualisasikan perbandingan antara nilai aktual dan nilai prediksi selama proses pelatihan, disajikan grafik pada Gambar 4.1. Grafik tersebut menampilkan kurva aktual dan prediksi terhadap seluruh data latih, yang menunjukkan sejauh mana model dapat mengikuti pola data aktual.



Gambar 4.1 Perbandingan Nilai Aktual dan Prediksi Tanpa Optimasi

Berdasarkan Gambar 4.1, terlihat bahwa garis prediksi (oranye) cenderung mengikuti pola dari garis aktual (biru), meskipun masih terdapat beberapa perbedaan yang cukup signifikan pada titik-titik tertentu. Hal ini mengindikasikan bahwa model dasar SVR dengan parameter *default* sudah cukup baik dalam menangkap pola data, namun masih perlu dilakukan optimasi untuk meningkatkan akurasi prediksi. Nilai *Mean Squared Error* (MSE) yang diperoleh adalah 0.091389, dengan RMSE sebesar 0.302307, serta koefisien determinasi (R^2) sebesar

0.928987. Nilai R^2 yang mendekati 1 menunjukkan bahwa model mampu menjelaskan sebagian besar variabilitas data, meskipun masih terdapat ruang untuk perbaikan melalui optimasi *hyperparameter*.

Pada skenario kedua, dilakukan optimasi *hyperparameter* untuk meningkatkan kemampuan model dalam mempelajari pola data. Proses optimasi dilakukan menggunakan metode *Grid Search* dengan mengevaluasi seluruh kombinasi dari tiga *hyperparameter* utama, yaitu parameter C , *epsilon* (ϵ), dan *gamma* (γ). Masing-masing parameter diuji menggunakan tiga nilai yang berbeda, yaitu $C = 1, 10$, dan 100 ; $\epsilon = 0,01, 0,1$, dan $0,2$; serta $\gamma = 0,01, 0,1$, dan $0,2$, sehingga menghasilkan total 27 kombinasi parameter. Ruang pencarian *hyperparameter* yang digunakan disajikan pada Tabel 4.7.

Tabel 4.7 Pencarian Hyperparameter dengan *Grid Search*

Parameter	Nilai
Kernel	Radial Basis Function (RBF)
C	1, 10, 100
Epsilon	0.01, 0.1, 0.2
Gamma	0.01, 0.1, 0.2

Untuk menjaga karakteristik data deret waktu, proses validasi selama optimasi dilakukan menggunakan metode *TimeSeriesSplit* dengan 5-fold. Pendekatan ini mempertahankan urutan kronologis data sehingga dapat mengurangi risiko terjadinya *data leakage*. Kinerja setiap kombinasi *hyperparameter* dievaluasi menggunakan metrik *Root Mean Squared Error* (RMSE), di mana nilai RMSE yang lebih kecil menunjukkan performa model yang lebih baik.

Hasil evaluasi seluruh kombinasi *hyperparameter* selama proses *Grid Search* disajikan pada Tabel 4.8.

Tabel 4.8 Hasil Evaluasi Kombinasi *Hyperparameter*

C	Epsilon	Gamma	RMSE	Standar Deviasi
1	0.01	0.01	0.172674	0.112131
1	0.01	0.1	0.066980	0.034729
1	0.01	0.2	0.056952	0.027670
1	0.1	0.01	0.171256	0.113671
1	0.1	0.1	0.120949	0.069328
1	0.1	0.2	0.114041	0.057981
1	0.2	0.01	0.175186	0.110143
1	0.2	0.1	0.160253	0.092663
1	0.2	0.2	0.164032	0.084729
10	0.01	0.01	0.066246	0.034583
10	0.01	0.1	0.043562	0.013050
10	0.01	0.2	0.042669	0.014454
10	0.1	0.01	0.120379	0.067800
10	0.1	0.1	0.095112	0.050579
10	0.1	0.2	0.096036	0.051193
10	0.2	0.01	0.160411	0.091985
10	0.2	0.1	0.158762	0.087807
10	0.2	0.2	0.160167	0.087487
100	0.01	0.01	0.043184	0.013039
100	0.01	0.1	0.038695	0.016944
100	0.01	0.2	0.041396	0.019305
100	0.1	0.01	0.094047	0.049664
100	0.1	0.1	0.094563	0.045628
100	0.1	0.2	0.095360	0.045497
100	0.2	0.01	0.157478	0.088109
100	0.2	0.1	0.158762	0.087807
100	0.2	0.2	0.160167	0.087487

Berdasarkan Tabel 4.8, terlihat bahwa performa model dipengaruhi oleh kombinasi *hyperparameter* yang digunakan. Nilai RMSE hasil validasi silang menunjukkan variasi yang cukup signifikan, yaitu mulai dari 0.175186 hingga 0.038695. Hal ini menunjukkan bahwa pemilihan *hyperparameter* yang tepat berperan penting dalam meningkatkan kemampuan model dalam mempelajari pola data.

Pola hasil pengujian menunjukkan bahwa nilai epsilon (ϵ) sebesar 0,01 secara konsisten menghasilkan nilai RMSE yang lebih rendah dibandingkan nilai epsilon yang lebih besar. Kondisi ini mengindikasikan bahwa model bekerja lebih optimal ketika menggunakan batas toleransi kesalahan yang lebih kecil sehingga lebih sensitif terhadap perbedaan antara nilai aktual dan nilai prediksi.

Selain itu, peningkatan nilai parameter C dari 1 menjadi 100 cenderung menurunkan nilai RMSE, terutama pada kombinasi dengan *epsilon* sebesar 0,01. Hasil ini menunjukkan bahwa model membutuhkan penalti kesalahan yang lebih besar agar mampu mempelajari pola data secara lebih akurat. Sementara itu, parameter *gamma* (γ) juga berpengaruh terhadap kemampuan generalisasi model. Pada penelitian ini, nilai gamma sebesar 0,1 menghasilkan keseimbangan terbaik antara kompleksitas model dan kemampuan mengikuti pola data. Hal tersebut tercermin dari nilai RMSE yang rendah serta standar deviasi yang relatif kecil pada kombinasi parameter terbaik.

Berdasarkan hasil proses optimasi, diperoleh kombinasi *hyperparameter* terbaik yaitu $C = 100$, $\epsilon = 0,01$, dan $\gamma = 0,1$ dengan nilai RMSE validasi silang sebesar 0,038695. Kombinasi tersebut dipilih karena menghasilkan nilai RMSE terendah dibandingkan seluruh kombinasi parameter yang diuji. Ringkasan *hyperparameter* terbaik yang diperoleh dari proses *Grid Search* disajikan pada Tabel 4.9.

Tabel 4.9 Parameter Terbaik Hasil Optimasi *Grid Search*

Parameter	
Kernel	RBF
Nilai C	100
Nilai epsilon	0.01
Nilai gamma	0.1
RMSE	0.038695

Selanjutnya, model dengan hyperparameter terbaik hasil *Grid Search* dilatih kembali menggunakan seluruh data latih dengan konfigurasi parameter tersebut. Model berusaha menemukan fungsi hyperplane yang meminimalkan error berdasarkan kombinasi parameter terbaik yang telah diperoleh. Hasil proses pembelajaran pada data latih menggunakan model dengan optimasi Grid Search disajikan pada Tabel 4.10.


Tabel 4.10 Hasil *Training* Model dengan *Grid Search*

Actual Output	Predicted Output	Error	 Error 	Error²
0.74	0.661030	0.078970	0.078970	0.006236
0.68	0.760811	-0.080811	0.080811	0.006530
0.70	0.700930	-0.000930	0.000930	0.000001
0.69	0.720887	-0.030887	0.030887	0.000954
0.67	0.710908	-0.040908	0.040908	0.001673
.....				
1.84	1.769946	0.070054	0.070054	0.004908
1.86	1.859558	0.000442	0.000442	0.000000
1.64	1.879456	-0.239456	0.239456	0.057339
2.57	1.660280	-0.090280	0.090280	0.008151
1.56	1.590424	0.059576	0.059576	0.003549
MSE			0.043883	
RMSE			0.209482	
R²			0.965902	

Berdasarkan Tabel 4.10, terlihat bahwa model dengan optimasi hyperparameter menghasilkan nilai prediksi yang lebih mendekati nilai aktual dibandingkan model tanpa optimasi. Error yang dihasilkan juga cenderung lebih

kecil, dengan error terbesar terjadi pada data dengan nilai aktual 1.64 sebesar -0.239456, sedangkan error terkecil terjadi pada data dengan nilai aktual 0.70 sebesar -0.000930 dan data dengan nilai aktual 1.86 sebesar 0.000442. Hal ini menunjukkan bahwa optimasi hyperparameter berhasil meningkatkan kemampuan model dalam menangkap pola data secara lebih akurat.

Untuk memvisualisasikan perbandingan antara nilai aktual dan nilai prediksi selama proses pelatihan dengan model optimal, disajikan grafik pada Gambar 4.2. Grafik tersebut menampilkan kurva aktual dan prediksi terhadap seluruh data latih, yang menunjukkan sejauh mana model optimal dapat mengikuti pola data aktual.



Gambar 4.2 Perbandingan Nilai Aktual dan Prediksi dengan *Grid Search*

Berdasarkan Gambar 4.2, terlihat bahwa garis prediksi (berwarna oranye) hampir seluruhnya mengikuti pola dari garis aktual (berwarna biru) dengan penyimpangan yang sangat kecil. Hal ini mengindikasikan bahwa model SVR dengan optimasi hyperparameter menggunakan Grid Search mampu mempelajari

pola data secara lebih baik dibandingkan model tanpa optimasi. Nilai Mean Squared Error (MSE) yang diperoleh adalah 0.043883, dengan RMSE sebesar 0.209482, serta koefisien determinasi (R^2) sebesar 0.965902. Nilai R^2 yang meningkat dari 0.928987 pada model tanpa optimasi menjadi 0.965902 pada model dengan optimasi menunjukkan bahwa penambahan proses Grid Search berhasil meningkatkan kemampuan model dalam menjelaskan variabilitas data secara signifikan.

Model tanpa optimasi dan model dengan hyperparameter terbaik hasil Grid Search selanjutnya dievaluasi menggunakan data uji periode Januari 2018 hingga Desember 2020.

4.3 Hasil Evaluasi Model

Subbab ini menyajikan hasil evaluasi kinerja model prediksi harga komoditas karet yang dibangun menggunakan metode *Support Vector Regression* (SVR). Evaluasi dilakukan dengan membandingkan nilai aktual dengan nilai hasil prediksi untuk mengukur tingkat akurasi model. Evaluasi performa model dilakukan menggunakan metrik *Root Mean Squared Error* (RMSE), yang merepresentasikan rata-rata kesalahan prediksi model terhadap data aktual. Nilai RMSE yang lebih kecil menunjukkan bahwa model memiliki tingkat akurasi yang lebih baik dalam melakukan prediksi.

4.3.1 Hasil Evaluasi Model Tanpa Optimasi Hyperparameter

Model Support Vector Regression tanpa optimasi *hyperparameter* yang telah dilatih pada tahap sebelumnya selanjutnya digunakan untuk melakukan

prediksi pada data uji periode Januari 2018 hingga Desember 2020. Hasil prediksi model dibandingkan dengan data aktual untuk mengevaluasi kemampuan model dalam mempelajari pola pergerakan harga komoditas karet. Hasil lengkap prediksi model tanpa optimasi *hyperparameter* disajikan pada Tabel 4.11.

Tabel 4.11 Hasil Prediksi Model Tanpa Optimasi *Hyperparameter*

Bulan	Data Aktual	Data Prediksi
2018-01-01	1.72	1.775537
2018-02-01	1.72	1.809656
2018-03-01	1.76	1.809656
2018-04-01	1.73	1.826832
2018-05-01	1.70	1.814099
2018-06-01	1.56	1.800457
2018-07-01	1.47	1.723319
2018-08-01	1.47	1.661481
2018-09-01	1.44	1.661481
2018-10-01	1.43	1.638840
2018-11-01	1.35	1.631084
2018-12-01	1.44	1.565633
2019-01-01	1.59	1.638840
2019-02-01	1.65	1.741802
2019-03-01	1.72	1.775537
2019-04-01	1.72	1.809656
2019-05-01	1.77	1.809656
2019-06-01	1.93	1.830886
2019-07-01	1.67	1.886055
2019-08-01	1.50	1.785844
2019-09-01	1.50	1.683134
2019-10-01	1.43	1.683134
2019-11-01	1.54	1.631084
2019-12-01	1.66	1.710397
2020-01-01	1.68	1.780748
2020-02-01	1.61	1.790826
2020-03-01	1.50	1.753523
2020-04-01	1.33	1.683134
2020-05-01	1.35	1.548441
2020-06-01	1.40	1.565633
2020-07-01	1.48	1.607219
2020-08-01	1.70	1.668810
2020-09-01	1.86	1.800457


2020-10-01	2.19	1.863751
2020-11-01	2.30	1.973660
2020-12-01	2.33	2.029022

Berdasarkan hasil pengujian, model *Support Vector Regression* tanpa optimasi *hyperparameter* menghasilkan nilai RMSE sebesar 0,188203. Nilai tersebut menunjukkan bahwa model masih memiliki tingkat kesalahan prediksi yang relatif tinggi sehingga kemampuan model dalam merepresentasikan pola data belum optimal.

Berdasarkan Tabel 4.11, terlihat bahwa model SVR tanpa optimasi *hyperparameter* mampu menghasilkan nilai prediksi yang secara umum mengikuti pola pergerakan harga aktual. Hal ini ditunjukkan oleh kecenderungan nilai prediksi yang bergerak searah dengan data aktual pada sebagian besar periode pengujian. Namun demikian, masih terdapat perbedaan yang cukup jelas antara nilai aktual dan nilai prediksi pada beberapa periode.

Pada awal tahun 2018, model cenderung menghasilkan nilai prediksi yang lebih tinggi dibandingkan nilai aktual (*overestimate*), terutama pada periode Januari hingga April 2018. Pola serupa juga terlihat pada beberapa periode lainnya, seperti pertengahan tahun 2019. Selain itu, pada akhir periode pengujian, khususnya selama tahun 2020, model menunjukkan kecenderungan menghasilkan nilai prediksi yang lebih rendah dibandingkan nilai aktual (*underestimate*). Kondisi ini terlihat pada bulan Oktober hingga Desember 2020 ketika harga aktual mengalami kenaikan yang cukup signifikan, namun model belum mampu menangkap lonjakan tersebut secara optimal.

Untuk memberikan gambaran yang lebih jelas mengenai hasil prediksi model, dilakukan visualisasi perbandingan antara data aktual dan data prediksi sebagaimana ditunjukkan pada Gambar 4.3.



Gambar 4.3 Visualisasi Hasil Prediksi Model Tanpa Optimasi

Berdasarkan Gambar 4.3, terlihat bahwa model *Support Vector Regression* (SVR) tanpa optimasi *hyperparameter* mampu mengikuti pola umum pergerakan harga karet, namun belum sepenuhnya akurat dalam menangkap fluktuasi data secara rinci. Hal ini ditunjukkan oleh adanya selisih yang cukup terlihat antara garis data aktual dan garis prediksi pada beberapa periode pengujian.

Pada awal periode pengujian, nilai prediksi cenderung berada di atas nilai aktual sehingga menunjukkan adanya kecenderungan *overestimate*. Selanjutnya, pada periode pertengahan hingga akhir tahun 2019, model mulai mampu mengikuti tren kenaikan dan penurunan harga, meskipun masih terdapat deviasi yang cukup besar ketika terjadi perubahan harga yang lebih tajam. Memasuki tahun 2020, khususnya menjelang akhir periode pengujian, model menunjukkan kecenderungan

underestimate karena tidak mampu mengikuti lonjakan harga yang terjadi secara signifikan.

4.3.2 Hasil Evaluasi Model dengan Optimasi *Hyperparameter*

Model *Support Vector Regression* (SVR) dengan kombinasi *hyperparameter* terbaik hasil optimasi *Grid Search* selanjutnya digunakan untuk melakukan prediksi pada data uji periode Januari 2018 hingga Desember 2020. Hasil prediksi model dibandingkan dengan data aktual untuk mengevaluasi peningkatan performa yang diperoleh setelah dilakukan optimasi *hyperparameter*. Hasil lengkap prediksi model dengan optimasi *hyperparameter* disajikan pada Tabel 4.12.

Tabel 4.12 Hasil Prediksi Model dengan Optimasi *Hyperparameter*

Bulan	Data Aktual	Data Prediksi
2018-01-01	1.72	1.670256
2018-02-01	1.72	1.740052
2018-03-01	1.76	1.740052
2018-04-01	1.73	1.779909
2018-05-01	1.70	1.750018
2018-06-01	1.56	1.720116
2018-07-01	1.47	1.580441
2018-08-01	1.47	1.490555
2018-09-01	1.44	1.490555
2018-10-01	1.43	1.460580
2018-11-01	1.35	1.450587
2018-12-01	1.44	1.370623
2019-01-01	1.59	1.460580
2019-02-01	1.65	1.610388
2019-03-01	1.72	1.670256
2019-04-01	1.72	1.740052
2019-05-01	1.77	1.740052
2019-06-01	1.93	1.789870
2019-07-01	1.67	1.949049
2019-08-01	1.50	1.690203
2019-09-01	1.50	1.520524


2019-10-01	1.43	1.520524
2019-11-01	1.54	1.450587
2019-12-01	1.66	1.560472
2020-01-01	1.68	1.680230
2020-02-01	1.61	1.700175
2020-03-01	1.50	1.630348
2020-04-01	1.33	1.520524
2020-05-01	1.35	1.350628
2020-06-01	1.40	1.370623
2020-07-01	1.48	1.420605
2020-08-01	1.70	1.500545
2020-09-01	1.86	1.720116
2020-10-01	2.19	1.879456
2020-11-01	2.30	2.206754
2020-12-01	2.33	2.315348

Berdasarkan hasil pengujian, model *Support Vector Regression* dengan optimasi *hyperparameter* menghasilkan nilai RMSE sebesar 0,115199. Nilai tersebut lebih kecil dibandingkan RMSE model tanpa optimasi yang sebesar 0,188203. Hasil ini menunjukkan bahwa proses optimasi *hyperparameter* berhasil meningkatkan akurasi model dalam memprediksi harga komoditas karet.

Berdasarkan Tabel 4.12, terlihat bahwa model SVR dengan optimasi *hyperparameter* mampu mengikuti pola pergerakan harga karet dengan lebih baik dibandingkan model tanpa optimasi. Nilai prediksi yang dihasilkan cenderung lebih mendekati nilai aktual pada sebagian besar periode pengujian.

Meskipun demikian, masih terdapat beberapa selisih antara nilai aktual dan nilai prediksi, terutama pada periode yang mengalami fluktuasi harga cukup tinggi, seperti akhir tahun 2020. Hal ini menunjukkan bahwa meskipun model telah dioptimasi, masih terdapat keterbatasan dalam menangkap perubahan harga yang sangat dinamis.

Untuk memberikan gambaran yang lebih jelas mengenai hasil prediksi model, dilakukan visualisasi perbandingan antara data aktual dan data prediksi sebagaimana ditunjukkan pada Gambar 4.4.



Gambar 4.4 Hasil Prediksi Model dengan Optimasi *Hyperparameter*

Berdasarkan Gambar 4.4, terlihat bahwa model *Support Vector Regression* (SVR) dengan optimasi *hyperparameter* mampu mengikuti pola pergerakan harga karet dengan lebih baik dibandingkan model tanpa optimasi. Garis prediksi tampak lebih mendekati garis data aktual pada hampir seluruh periode pengujian, yang menunjukkan peningkatan kemampuan model dalam menangkap pola data deret waktu.

Pada periode awal tahun 2018, nilai prediksi sudah cukup mendekati nilai aktual dengan selisih yang relatif kecil. Memasuki tahun 2019, model juga mampu mengikuti tren kenaikan dan penurunan harga dengan lebih konsisten, meskipun masih terdapat sedikit deviasi pada beberapa titik pengamatan. Pada periode tahun 2020, terutama ketika terjadi fluktuasi harga yang signifikan, model hasil optimasi

menunjukkan kemampuan yang lebih baik dalam mengikuti arah pergerakan data dibandingkan model tanpa optimasi.

4.3.3 Perbandingan Kinerja Model *Support Vector Regression* (SVR)

Pada subbab ini dilakukan perbandingan kinerja antara model *Support Vector Regression* (SVR) tanpa optimasi *hyperparameter* dan model SVR dengan optimasi *hyperparameter*. Tujuan dari perbandingan ini adalah untuk mengetahui pengaruh optimasi *hyperparameter* terhadap tingkat akurasi prediksi harga komoditas karet pada data uji periode Januari 2018 hingga Desember 2020.

Perbandingan kinerja model dilakukan menggunakan metrik *Root Mean Squared Error* (RMSE). Berdasarkan hasil evaluasi yang telah diperoleh, model SVR tanpa optimasi *hyperparameter* menghasilkan nilai RMSE sebesar 0,188203, sedangkan model SVR dengan optimasi *hyperparameter* menghasilkan nilai RMSE sebesar 0,115199. Nilai RMSE yang lebih rendah pada model hasil optimasi menunjukkan bahwa model tersebut memiliki tingkat kesalahan prediksi yang lebih kecil dibandingkan model tanpa optimasi.

Penurunan nilai RMSE sebesar 0,073004 menunjukkan bahwa optimasi *hyperparameter* memberikan peningkatan performa model dalam mempelajari pola data harga komoditas karet. Hasil ini mengindikasikan bahwa pemilihan kombinasi *hyperparameter* yang tepat berperan penting dalam meningkatkan kemampuan model untuk menghasilkan prediksi yang lebih akurat.

Selain berdasarkan nilai RMSE, perbandingan kinerja model juga dianalisis melalui hasil prediksi pada data uji yang disajikan pada Tabel 4.13.

Tabel 4.13 Perbandingan Hasil Prediksi Model

Bulan	Data Aktual	Prediksi Tanpa Optimasi	Prediksi Optimasi
2018-01-01	1.72	1.775537	1.670256
2018-02-01	1.72	1.809656	1.740052
2018-03-01	1.76	1.809656	1.740052
2018-04-01	1.73	1.826832	1.779909
2018-05-01	1.70	1.814099	1.750018
2018-06-01	1.56	1.800457	1.720116
2018-07-01	1.47	1.723319	1.580441
2018-08-01	1.47	1.661481	1.490555
2018-09-01	1.44	1.661481	1.490555
2018-10-01	1.43	1.638840	1.460580
2018-11-01	1.35	1.631084	1.450587
2018-12-01	1.44	1.565633	1.370623
2019-01-01	1.59	1.638840	1.460580
2019-02-01	1.65	1.741802	1.610388
2019-03-01	1.72	1.775537	1.670256
2019-04-01	1.72	1.809656	1.740052
2019-05-01	1.77	1.809656	1.740052
2019-06-01	1.93	1.830886	1.789870
2019-07-01	1.67	1.886055	1.949049
2019-08-01	1.50	1.785844	1.690203
2019-09-01	1.50	1.683134	1.520524
2019-10-01	1.43	1.683134	1.520524
2019-11-01	1.54	1.631084	1.450587
2019-12-01	1.66	1.710397	1.560472
2020-01-01	1.68	1.780748	1.680230
2020-02-01	1.61	1.790826	1.700175
2020-03-01	1.50	1.753523	1.630348
2020-04-01	1.33	1.683134	1.520524
2020-05-01	1.35	1.548441	1.350628
2020-06-01	1.40	1.565633	1.370623
2020-07-01	1.48	1.607219	1.420605
2020-08-01	1.70	1.668810	1.500545
2020-09-01	1.86	1.800457	1.720116
2020-10-01	2.19	1.863751	1.879456
2020-11-01	2.30	1.973660	2.206754
2020-12-01	2.33	2.029022	2.315348


Berdasarkan Tabel 4.13, terlihat bahwa kedua model pada dasarnya mampu mengikuti pola umum pergerakan harga komoditas karet selama periode pengujian. Namun demikian, terdapat perbedaan tingkat kedekatan antara nilai prediksi dan nilai aktual yang dihasilkan oleh masing-masing model.

Model tanpa optimasi *hyperparameter* cenderung menghasilkan nilai prediksi yang memiliki deviasi lebih besar terhadap data aktual. Kondisi ini terlihat pada beberapa periode, terutama ketika terjadi perubahan harga yang cukup signifikan. Pada awal periode pengujian, model sering menghasilkan prediksi yang lebih tinggi dibandingkan nilai aktual (*overestimate*), sedangkan pada akhir periode pengujian model cenderung menghasilkan prediksi yang lebih rendah dibandingkan nilai aktual (*underestimate*).

Sebaliknya, model dengan optimasi *hyperparameter* menghasilkan nilai prediksi yang secara umum lebih mendekati data aktual pada sebagian besar periode pengujian. Selisih antara nilai aktual dan nilai prediksi relatif lebih kecil dibandingkan model tanpa optimasi, yang menunjukkan bahwa model hasil optimasi memiliki kemampuan yang lebih baik dalam merepresentasikan pola data deret waktu harga karet.

Meskipun demikian, kedua model masih menunjukkan keterbatasan dalam menangkap perubahan harga yang bersifat ekstrem. Kondisi ini terlihat pada akhir tahun 2020 ketika harga karet mengalami kenaikan yang cukup tajam. Walaupun model hasil optimasi mampu mengikuti arah kenaikan harga dengan lebih baik, masih terdapat selisih antara nilai aktual dan nilai prediksi yang dihasilkan.

Untuk memberikan gambaran yang lebih komprehensif mengenai perbedaan performa kedua model, dilakukan visualisasi perbandingan antara data aktual, hasil prediksi model tanpa optimasi, dan hasil prediksi model dengan optimasi sebagaimana ditunjukkan pada Gambar 4.5.



Gambar 4.5 Visualisasi Perbandingan Hasil Prediksi Model


Berdasarkan Gambar 4.5, terlihat bahwa garis prediksi model dengan optimasi *hyperparameter* berada lebih dekat dengan garis data aktual dibandingkan model tanpa optimasi pada sebagian besar periode pengujian. Hal ini menunjukkan bahwa model hasil optimasi mampu mengikuti pola pergerakan harga komoditas karet dengan lebih baik.

Selain itu, fluktuasi yang ditunjukkan oleh model hasil optimasi tampak lebih responsif terhadap perubahan pola data dibandingkan model tanpa optimasi. Meskipun kedua model masih mengalami kesulitan dalam menangkap lonjakan harga yang terjadi pada akhir periode pengamatan, model hasil optimasi tetap menunjukkan tingkat kedekatan yang lebih tinggi terhadap nilai aktual.

Berdasarkan hasil perbandingan nilai RMSE, hasil prediksi, dan visualisasi model, dapat disimpulkan bahwa optimasi *hyperparameter* menggunakan metode *Grid Search* berhasil meningkatkan kinerja model *Support Vector Regression* (SVR) dalam memprediksi harga komoditas karet. Model dengan optimasi *hyperparameter* menghasilkan prediksi yang lebih akurat dan lebih konsisten dibandingkan model tanpa optimasi, sehingga lebih efektif digunakan untuk memodelkan data deret waktu harga komoditas karet pada penelitian ini.

4.4 Pembahasan

Berdasarkan hasil optimasi *hyperparameter* menggunakan metode *Grid Search*, diketahui bahwa parameter C , *epsilon* (ϵ), dan *gamma* (γ) memberikan pengaruh yang berbeda terhadap kinerja model *Support Vector Regression* (SVR). Pengaruh masing-masing parameter dianalisis berdasarkan perubahan rata-rata nilai *Root Mean Squared Error* (RMSE) yang diperoleh dari seluruh kombinasi parameter yang diuji. Analisis ini dilakukan untuk mengetahui sejauh mana setiap *hyperparameter* berkontribusi terhadap peningkatan akurasi model dalam memprediksi harga komoditas karet.




Gambar 4.6 Pengaruh Parameter C

Berdasarkan Gambar 4.6, terlihat bahwa peningkatan nilai parameter C cenderung menurunkan rata-rata RMSE model. Nilai rata-rata RMSE mengalami penurunan dari 0.133591 pada $C = 1$ menjadi 0.104816 pada $C = 10$, kemudian kembali menurun menjadi 0.098184 pada $C = 100$. Hasil tersebut menunjukkan bahwa peningkatan nilai C berkontribusi terhadap peningkatan akurasi model dalam memprediksi harga komoditas karet.

Meskipun demikian, penurunan RMSE yang terjadi tidak bersifat linear. Penurunan rata-rata RMSE dari $C = 1$ ke $C = 10$ terlihat lebih besar dibandingkan penurunan dari $C = 10$ ke $C = 100$. Kondisi ini menunjukkan bahwa setelah mencapai nilai tertentu, peningkatan nilai C hanya memberikan tambahan peningkatan performa yang relatif kecil. Dengan demikian, nilai C yang lebih besar mampu meningkatkan kemampuan model dalam mempelajari pola data, namun peningkatan akurasi yang diperoleh cenderung semakin terbatas pada nilai C yang tinggi.

Selain parameter C , performa model juga dipengaruhi oleh parameter *epsilon* (ϵ). Untuk mengetahui pengaruh parameter tersebut terhadap tingkat kesalahan prediksi model, dilakukan analisis berdasarkan perubahan rata-rata nilai RMSE pada setiap nilai *epsilon* yang diuji. Hasil analisis disajikan pada Gambar 4.7.




Gambar 4.7 Pengaruh Parameter *Epsilon*

Berdasarkan Gambar 4.7, terlihat bahwa peningkatan nilai *epsilon* menyebabkan rata-rata RMSE meningkat secara konsisten. Nilai rata-rata RMSE terendah diperoleh pada epsilon sebesar 0.01, yaitu 0.063595, sedangkan nilai rata-rata RMSE tertinggi diperoleh pada epsilon sebesar 0.2, yaitu 0.161691. Pola tersebut menunjukkan bahwa perubahan nilai epsilon memberikan pengaruh yang cukup besar terhadap performa model.

Peningkatan nilai epsilon dari 0.01 menjadi 0.2 menyebabkan kenaikan rata-rata RMSE yang signifikan. Dibandingkan parameter lainnya, perubahan RMSE akibat variasi *epsilon* merupakan yang paling besar. Hasil ini menunjukkan bahwa model lebih mampu menghasilkan prediksi yang akurat ketika menggunakan nilai epsilon yang relatif kecil. Dengan kata lain, parameter epsilon menjadi faktor yang paling menentukan dalam meningkatkan maupun menurunkan performa model pada penelitian ini.

Selanjutnya, analisis dilakukan terhadap parameter *gamma* (γ) untuk mengetahui pengaruhnya terhadap performa model. Pengaruh parameter gamma

diamati melalui perubahan rata-rata nilai RMSE yang dihasilkan pada setiap nilai *gamma* yang diuji. Hasil analisis ditunjukkan pada Gambar 4.8.



Gambar 4.8 Pengaruh Parameter *Gamma*

Berdasarkan Gambar 4.8, terlihat bahwa peningkatan nilai *gamma* cenderung menurunkan rata-rata RMSE model. Nilai rata-rata RMSE mengalami penurunan dari 0.128985 pada $\gamma = 0.01$ menjadi 0.104182 pada $\gamma = 0.1$, kemudian sedikit menurun menjadi 0.103424 pada $\gamma = 0.2$. Hasil tersebut menunjukkan bahwa peningkatan nilai *gamma* mampu meningkatkan kemampuan model dalam mengikuti pola data yang bersifat nonlinier.

Namun demikian, penurunan RMSE yang terjadi setelah *gamma* mencapai nilai 0.1 relatif kecil. Perbedaan rata-rata RMSE antara $\gamma = 0.1$ dan $\gamma = 0.2$ hanya sebesar 0.000758. Hal ini menunjukkan bahwa peningkatan nilai *gamma* setelah mencapai tingkat tertentu tidak memberikan peningkatan performa yang signifikan. Dengan demikian, pengaruh parameter *gamma* terhadap perubahan akurasi model cenderung lebih kecil dibandingkan parameter epsilon maupun parameter C.

Berdasarkan hasil analisis terhadap ketiga hyperparameter tersebut, dapat diidentifikasi bahwa setiap parameter memberikan kontribusi yang berbeda terhadap performa model. Parameter *epsilon* menunjukkan pengaruh yang paling besar terhadap perubahan nilai RMSE, diikuti oleh parameter *C* dan *gamma*. Hasil ini mengindikasikan bahwa akurasi model SVR pada penelitian ini lebih sensitif terhadap perubahan nilai *epsilon* dibandingkan perubahan nilai *hyperparameter* lainnya.

Secara keseluruhan, hasil optimasi menunjukkan bahwa kombinasi *hyperparameter* $C = 100$, $epsilon = 0.01$, dan $gamma = 0.1$ menghasilkan nilai RMSE validasi silang terendah sebesar 0.038695. Kombinasi tersebut mampu memberikan keseimbangan terbaik dalam mempelajari pola data harga komoditas karet sehingga menghasilkan tingkat kesalahan prediksi yang paling rendah dibandingkan seluruh kombinasi parameter yang diuji. Oleh karena itu, kombinasi *hyperparameter* tersebut dipilih sebagai konfigurasi optimal pada model *Support Vector Regression* (SVR) dalam penelitian ini.

4.5 Integrasi Islam

Integrasi nilai-nilai Islam dalam penelitian ini bertujuan untuk mengaitkan hasil kajian ilmiah dengan prinsip-prinsip yang terdapat dalam ajaran Islam, khususnya dalam aspek perencanaan dan pengambilan keputusan. Dalam perspektif Islam, aktivitas keilmuan tidak hanya berfungsi sebagai sarana untuk memperoleh pengetahuan, tetapi juga sebagai bentuk ikhtiar manusia dalam menghadapi ketidakpastian serta menciptakan kemaslahatan dalam kehidupan.

Dalam konteks penelitian ini, penggunaan metode *Support Vector Regression* (SVR) untuk memprediksi harga komoditas karet dapat dipandang sebagai bentuk upaya sistematis dalam memahami pola masa lalu guna merencanakan kondisi masa depan. Oleh karena itu, integrasi Islam dalam penelitian ini difokuskan pada dua aspek utama, yaitu konsep perencanaan dan pengambilan keputusan dalam perspektif Al-Qur'an.

4.5.1 Konsep Perencanaan Dalam Perspektif Alqur'an

Dalam Islam, konsep perencanaan masa depan merupakan bagian dari ikhtiar manusia dalam menghadapi ketidakpastian kehidupan. Prinsip ini tercermin secara jelas dalam firman Allah Swt. pada Surah Yusuf ayat 47–49 yang menceritakan strategi Nabi Yusuf dalam menghadapi masa paceklik:

قَالَ تَزْرَعُونَ سَبْعَ سِنِينَ دَأَبًا فَمَا حَصَدْتُمْ فَذَرُوهُ فِي سُنْبُلِهِ إِلَّا قَلِيلًا مِّمَّا تَأْكُلُونَ ﴿٤٧﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ سَبْعٌ شِدَادٌ يَأْكُلْنَ مَا قَدَّمْتُمْ هُنَّ إِلَّا قَلِيلًا مِّمَّا تُخْصِنُونَ ﴿٤٨﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ عَامٌ فِيهِ يُغَاثُ النَّاسُ وَفِيهِ يَعْرِضُونَ ﴿٤٩﴾

“(Yusuf) berkata: ‘Bercocok tanamlah kamu tujuh tahun (lamanya) sebagaimana biasa; maka apa yang kamu tuai hendaklah kamu biarkan di bulirnya kecuali sedikit untuk kamu makan. Kemudian setelah itu akan datang tujuh tahun yang sangat sulit yang menghabiskan apa yang kamu simpan untuk menghadapinya, kecuali sedikit dari apa yang kamu simpan. Kemudian setelah itu akan datang tahun di mana manusia diberi hujan (dengan cukup) dan pada masa itu mereka memeras anggur.’” (QS. Yusuf: 47–49)

Ayat tersebut menunjukkan bahwa Nabi Yusuf a.s. tidak hanya menyampaikan tafsir mimpi, tetapi juga merumuskan strategi ekonomi berbasis prediksi jangka panjang. Dalam tafsir al-misbah karya Quraish Shihab dijelaskan bahwa perintah untuk menyimpan hasil panen di tangkainya merupakan bentuk

manajemen sumber daya yang efisien untuk menghadapi krisis yang akan datang. Hal ini menunjukkan adanya proses analisis terhadap kondisi masa depan berdasarkan informasi yang tersedia (Hani & Fadliyati, 2020).

Dalam konteks penelitian ini, konsep tersebut sejalan dengan pendekatan forecasting, di mana data historis digunakan untuk memprediksi kondisi masa depan. Model *Support Vector Regression* (SVR) yang digunakan dalam penelitian ini bekerja dengan mengidentifikasi pola dari data harga karet pada periode sebelumnya untuk menghasilkan prediksi yang lebih akurat. Dengan demikian, penggunaan metode prediksi dalam penelitian ini dapat dipandang sebagai implementasi nilai-nilai perencanaan yang telah diajarkan dalam Al-Qur'an.

Selain itu, ayat ini juga mengandung prinsip kehati-hatian dan antisipasi risiko, yang dalam ilmu ekonomi modern dikenal sebagai risk management. Hal ini menunjukkan bahwa ajaran Islam tidak hanya bersifat normatif, tetapi juga memiliki relevansi dengan konsep-konsep ilmiah kontemporer dalam pengelolaan ketidakpastian.

4.5.2 Pengambilan Keputusan Dalam Perspektif Islam

Dalam ajaran Islam, pengambilan keputusan merupakan bagian penting dari proses perencanaan yang harus dilakukan secara bijaksana dan berdasarkan pertimbangan yang matang. Setelah suatu prediksi atau perencanaan disusun, langkah selanjutnya adalah menentukan tindakan yang tepat agar tujuan yang diharapkan dapat tercapai secara optimal.

Hal ini sejalan dengan firman Allah Swt. Pada surah *Al-Hasyr* Ayat 18:

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ إِنَّ اللَّهَ خَبِيرٌ بِمَا تَعْمَلُونَ ﴿١٨﴾

“Wahai orang-orang yang beriman! Bertakwalah kepada Allah dan hendaklah setiap diri memperhatikan apa yang telah diperbuatnya untuk hari esok (akhirat). Bertakwalah kepada Allah. Sesungguhnya Allah Maha Teliti terhadap apa yang kamu kerjakan” (QS. Al-Hasyr: 18)

Dalam Tafsir Al-Misbah, ayat ini dijelaskan sebagai dorongan bagi manusia untuk tidak hanya berfokus pada kondisi saat ini, tetapi juga mempertimbangkan dampak dari setiap keputusan terhadap masa depan. Dengan demikian, setiap keputusan hendaknya didasarkan pada analisis yang rasional serta pertimbangan yang matang (Rahman et al., 2023).

Jika dikaitkan dengan kisah Nabi Yusuf a.s. dalam Surah Yusuf ayat 47–49, keputusan untuk menyimpan hasil panen selama masa subur merupakan langkah strategis yang diambil berdasarkan hasil prediksi yang telah dilakukan sebelumnya. Hal ini menunjukkan bahwa prediksi yang baik harus diikuti dengan pengambilan keputusan yang tepat agar dapat memberikan manfaat yang optimal.

Dalam konteks penelitian ini, hasil prediksi harga karet yang diperoleh dari model *Support Vector Regression* (SVR) dapat dimanfaatkan sebagai dasar dalam pengambilan keputusan ekonomi. Model dengan optimasi *hyperparameter* menunjukkan tingkat akurasi yang lebih baik, yang ditandai dengan nilai RMSE yang lebih rendah dibandingkan model tanpa optimasi. Dengan demikian, informasi yang dihasilkan oleh model dapat digunakan sebagai referensi dalam menentukan strategi yang lebih tepat.

Sebagai contoh, petani karet dapat memanfaatkan hasil prediksi untuk menentukan waktu penjualan yang optimal, pelaku industri dapat merencanakan

kebutuhan bahan baku secara lebih efisien, serta pemerintah dapat menyusun kebijakan yang lebih adaptif terhadap fluktuasi harga. Hal ini menunjukkan bahwa pengambilan keputusan yang didasarkan pada informasi hasil prediksi akan lebih terarah dan memiliki dasar yang kuat.

Meskipun demikian, dalam Islam juga diajarkan bahwa hasil akhir tetap berada di luar kendali manusia. Oleh karena itu, pengambilan keputusan harus disertai dengan sikap kehati-hatian serta mempertimbangkan berbagai faktor yang dapat mempengaruhi kondisi di masa depan. Dengan demikian, hasil prediksi dalam penelitian ini sebaiknya digunakan sebagai alat bantu dalam proses pengambilan keputusan, bukan sebagai satu-satunya penentu.

Dengan demikian, dapat disimpulkan bahwa pengambilan keputusan dalam perspektif Islam menekankan keseimbangan antara perencanaan yang matang, penggunaan informasi yang akurat, serta kesadaran akan keterbatasan manusia. Prinsip ini sejalan dengan penggunaan metode prediksi dalam penelitian, di mana hasil analisis data digunakan untuk mendukung keputusan yang lebih rasional, terarah, dan memberikan manfaat yang optimal.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode *Support Vector Regression* (SVR) dengan kernel *Radial Basis Function* (RBF) mampu diterapkan untuk memprediksi harga komoditas karet berbasis data deret waktu (*time series*) periode Januari 2000 hingga Desember 2020. Hasil pengujian menunjukkan bahwa model mampu mengikuti pola umum pergerakan harga karet dan menghasilkan nilai prediksi yang mendekati data aktual pada sebagian besar periode pengujian.

Hasil penelitian menunjukkan bahwa optimasi *hyperparameter* menggunakan metode *Grid Search* dengan validasi *TimeSeriesSplit* berpengaruh terhadap peningkatan kinerja model. Berdasarkan proses optimasi yang dilakukan, diperoleh kombinasi *hyperparameter* terbaik yaitu $C = 100$, *epsilon* (ϵ) = 0.01, dan *gamma* (γ) = 0.1. Kombinasi parameter tersebut menghasilkan nilai RMSE validasi silang terendah yaitu 0.038695 dan digunakan untuk membangun model prediksi untuk data uji.

Berdasarkan evaluasi pada data uji, model SVR tanpa optimasi menghasilkan nilai RMSE sebesar 0.188203, sedangkan model SVR dengan optimasi *hyperparameter* menghasilkan nilai RMSE sebesar 0.115199. Penurunan nilai RMSE tersebut menunjukkan bahwa optimasi *hyperparameter* mampu

meningkatkan akurasi prediksi model dibandingkan penggunaan parameter bawaan.

5.2 Saran

Berdasarkan hasil dan keterbatasan penelitian yang telah dilakukan, terdapat beberapa saran untuk penelitian selanjutnya, penelitian selanjutnya disarankan untuk menambahkan variabel atau faktor lain yang berpotensi memengaruhi harga komoditas karet, seperti nilai tukar, konflik global, maupun faktor ekonomi lainnya. Penambahan variabel tersebut diharapkan dapat meningkatkan kemampuan model dalam menangkap perubahan harga yang tidak dapat dijelaskan hanya berdasarkan data historis harga karet.

DAFTAR PUSTAKA

- Amalia, A., Hayati, I., Afandi, A., Lubis, A. S., & Marpaung, J. L. (2025). Comparative Forecasting of Indonesian Stock Prices Using ARIMA and Support Vector Regression: A Statistical Learning Approach. *Mathematical Modelling of Engineering Problems*, 12(7), 2307–2315. <https://doi.org/10.18280/mmep.120711>
- Anamisa, D. R., Khotimah, B. K., Hariyawan, M. Y., Irhamni, F., Jauhari, A., Mufarroha, F. A., Violina, D., & Nuraini, D. (2025). Forecasting of Rice Harvest Results Using SVR Modeling Techniques. *Jambura Journal of Mathematics*, 7(1), 84–91. <https://doi.org/10.37905/jjom.v7i1.30592>
- Astiningrum, M., Wijayaningrum, V. N., & Putri, I. K. (2021). Forecasting Model of Staple Food Prices Using Support Vector Regression with Optimized Parameters. *Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika*, 7(3), 441. <https://doi.org/10.26555/jiteki.v7i3.22010>
- Atika Mahgfirah, A., Hikmah, & Indi Rahayu, P. (2025). Analisis Support Vector Regression untuk Meramalkan Saham Perusahaan Dss di Indonesia. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 7(1), 44–54. <https://doi.org/10.35580/variansiunm356>
- Azis, H., Purnawansyah, P., Nirwana, N., & Dwiyanto, F. A. (2023a). The Support Vector Regression Method Performance Analysis in Predicting National Staple Commodity Prices. *ILKOM Jurnal Ilmiah*, 15(2), 390–397. <https://doi.org/10.33096/ilkom.v15i2.1686.390-397>
- Azis, H., Purnawansyah, P., Nirwana, N., & Dwiyanto, F. A. (2023b). The Support Vector Regression Method Performance Analysis in Predicting National Staple Commodity Prices. *ILKOM Jurnal Ilmiah*, 15(2), 390–397. <https://doi.org/10.33096/ilkom.v15i2.1686.390-397>
- Bagaskara, K., Perdana, H., & Aprizkiyandari, S. (2024). PENERAPAN SUPPORT VECTOR REGRESSION KERNEL LINIER DALAM MERAMALKAN HARGA CPO INDONESIA Informasi Artikel ABSTRAK Sejarah Artikel. *Equator: Journal of Mathematical and Statistical Sciences (EJMSS)*, 3(2), 74–83.
- Fajri, M., & Primajaya, A. (2023). Komparasi Teknik Hyperparameter Optimization pada SVM untuk Permasalahan Klasifikasi dengan Menggunakan Grid Search dan Random Search. *Journal of Applied Informatics and Computing (JAIC)*, 7(1), 10–15. <http://jurnal.polibatam.ac.id/index.php/JAIC>

- Fatima, S. S. W., & Rahimi, A. (2024). A Review of Time-Series Forecasting Algorithms for Industrial Manufacturing Systems. *Machines*, 12(6), 1–30. <https://doi.org/10.3390/machines12060380>
- Fauzani, S. P., & Rahmi, D. (2023). Penerapan Metode ARIMA Dalam Peramalan Harga Produksi Karet di Provinsi Riau. *Jurnal Teknologi Dan Manajemen Industri Terapan (JTMIT)*, 2(4), 269–277.
- Firdaus, R., Mukhtar, H., & Awaluddin. (2023). Prediksi Indeks Harga Produsen Pertanian Karet Di Indonesia Menggunakan Metode LSTM. *JURNAL FASILKOM*, 13(1), 01–06. <https://www.bappebti.go.id/>.
- Fitria, A. V., Purwani, D. S., & Rahmadhani, I. (2023). ANALISIS KINERJA EKSPOR KOMODITAS KARET DI INDONESIA. *Journal Science Innovation and Technology*, 3(2), 1–5.
- Fungki Wahyu, & Billy Hendrik. (2023). Perbandingan Algoritma Time Series Dan Fuzzy Inference System Dalam Analisis Data Deret Waktu. *Jurnal Penelitian Teknologi Informasi Dan Sains*, 1(3), 16–24. <https://doi.org/10.54066/jptis.v1i3.711>
- Guindani, L. G., Oliveirai, G. A., Ribeiro, M. H. D. M., Gonzalez, G. V., & de Lima, J. D. (2024). Exploring current trends in agricultural commodities forecasting methods through text mining: Developments in statistical and artificial intelligence methods. *Heliyon*, 10(23), 2–16. <https://doi.org/10.1016/j.heliyon.2024.e40568>
- Hadi, S. M. (2022). TELAAH TAKWIL KISAH MIMPI RAJA DALAM SURAT YUSUF AYAT 43-49 (ANALISIS SEMIOTIKA CHARLES SANDER PIERCE). *Jurnal Studi Islam*, 14(1), 44–61. <https://jurnalannur.ac.id/index.php/An-Nur>
- Hall, T., & Rasheed, K. (2025). A Survey of Machine Learning Methods for Time Series Prediction. *Applied Sciences*, 15(11), 1–33. <https://doi.org/10.3390/app15115957>
- Hani, J., & Fadliyati, N. (2020). Menabung Dalam Al-Qur'an: Tafsir Analysis QS. Yusuf Ayat 47-49. *AT-TIBYAN: Journal of Qur'an and Hadis Studies*, 3(2), 128–145.
- Hermawan, A., Mangku, I. W., Ardana, N. K. K., & Sumarno, H. (2022). ANALISIS SUPPORT VECTOR REGRESSION DENGAN ALGORITMA GRID SEARCH UNTUK MEMPREDIKSI HARGA SAHAM. *MILANG*, 18(1), 41–60.
- Ishlah, A. W., Sudarno, S., & Kartikasari, P. (2023). IMPLEMENTASI GRIDSEARCHCV PADA SUPPORT VECTOR REGRESSION (SVR) UNTUK PERAMALAN HARGA SAHAM. *Jurnal Gaussian*, 12(2), 276–286. <https://doi.org/10.14710/j.gauss.12.2.276-286>

- Isnaeni, R., Sudarmin, & Rais, Z. (2022). ANALISIS SUPPORT VECTOR REGRESSION (SVR) DENGAN KERNEL RADIAL BASIS FUNCTION (RBF) UNTUK MEMPREDIKSI LAJU INFLASI DI INDONESIA. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 4(1), 30–38. <https://doi.org/10.35580/variansiunm13>
- Juliandy, C., Kelvin, K., Halim, A., Pipin, S. J., Sinaga, F. M., & Lestari, W. S. (2024). Forecasting Climate Change Patterns to Improving Rice Harvest Using SVR for Achieving Green Economy. *Indonesian Journal of Artificial Intelligence and Data Mining*, 7(2), 520. <https://doi.org/10.24014/ijaidm.v7i2.32393>
- Khaswarina, S., Sucherly, Kaltum, U., & Rina Novianti Ariawaty, R. (2023). The Efficiency of Smallholder Rubber Plantations and the Factors That Influence It: A Case Study in Indonesia. *International Journal of Design and Nature and Ecodynamics*, 18(2), 261–267. <https://doi.org/10.18280/ijдне.180203>
- Krismawan, V., Muchtolifah, & Sishadiyati. (2021). Pengaruh Nilai Tukar, Produksi Karet Indonesia dan Harga Karet Indonesia Terhadap Ekspor Karet Indonesia Periode Tahun 2008 - 2019. *Jurnal Ekobis Dewantara*, 4(3), 134–143.
- Medyanti, W. A., Faisal, M., & Nurhayati, H. (2024). Optimasi Metode Single Exponential Smoothing Dengan Grid Search Pada Prediksi Nilai Ekspor Migas. *SCIENCE AND INFORMATION TECHNOLOGY: SINTECH JOURNAL*, 7(1), 59–69. <https://doi.org/10.31598>
- Nadir, R. A., & Sukmana, R. N. (2023). Sistem Prediksi Harga Emas Berdasarkan Data Time Series Menggunakan Metode Artificial Neural Network (ANN). *Digital Transformation Technology*, 3(2), 426–437. <https://doi.org/10.47709/digitech.v3i2.2877>
- Najib, M. K., & Nurdianti, S. (2025). Pemodelan Deret Waktu Menggunakan Non-linear Autoregressive Neural Network: Studi Kasus Prediksi Harga Saham Mandiri. *Jambura Journal of Mathematics*, 7(2), 213–220. <https://doi.org/10.37905/jjom.v7i2.33397>
- Nathansyah, E. (2025). Perbandingan Performa Metode Linear Regression, Support Vector Regression, Extreme Gradient Boosting Untuk Prediksi Kurs Mata Uang Rupiah Terhadap Dollar. *Computatio: Journal of Computer Science and Information Systems*, 9(1), 61–76.
- Ngatemi, N., Emilia, E., & Mustika, C. (2022). Pengaruh Produksi, Harga Karet Internasional dan Nilai Tukar terhadap Volume Ekspor Karet Alam Indonesia. *Jurnal Ekonomi Aktual*, 2(1), 13–22. <https://doi.org/10.53867/jea.v2i1.60>
- Ngestisari, W., Susanto, B., & Mahatma, T. (2020). Perbandingan Metode ARIMA dan Jaringan Syaraf Tiruan untuk Peramalan Harga Beras INFORMASI ARTIKEL ABSTRAK. *Indonesian Journal of Data and Science (IJODAS)*, 1(3), 96–107.

- Nurholipah, T., Kurniawan, R., & Wijaya, Y. A. (2024). Evaluasi Performa Model Regresi Linear Dengan RMSE Pada Jumlah Penumpang Bus Transjakarta. *JIKA (Jurnal Informatika)*, 8(2), 180–186. <https://doi.org/10.31000/jika.v8i2.10405>
- Pangaribuan, J. J., Fanny, Barus, O. P., & Romindo. (2023). Prediksi Penjualan Bisnis Rumah Properti Dengan Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA). *Jurnal Sistem Informasi Bisnis*, 13(2), 154–161. <https://doi.org/10.21456/vol13iss2pp154-161>
- Pradasyah, A., & Baita, A. (2025). Comparative Study of Support Vector Regression and Long Short-Term Memory for Stock Price Prediction. *Journal of Applied Informatics and Computing (JAIC)*, 9(4), 1301. <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Priyono, A., Firmansyah, H., Asriyani, W., & Tulodo, R. P. (2025). Analisis Pengaruh Parameter Support Vector Machine Terhadap Akurasi Prediksi Harga Saham. *Jurnal Pengabdian Masyarakat Dan Riset Pendidikan*, 4(3), 14686–14696. <https://doi.org/10.31004/jerkin.v4i3.4529>
- Purwoko, C. F. F., Sediono, S., Saifudin, T., & Mardianto, M. F. F. (2023a). Prediksi Harga Ekspor Non Migas di Indonesia Berdasarkan Metode Estimator Deret Fourier dan Support Vector Regression. *Inferensi*, 6(1), 45–55. <https://doi.org/10.12962/j27213862.v6i1.15558>
- Pusat Data dan Sistem Informasi. (2025). *REALISASI EKSPOR KARET DAN PRODUK KARET INDONESIA TAHUN 2018-2023 (JANUARI-MEI)*. <https://satudata.kemendag.go.id/ringkasan/produk#>
- Putra, R. F. D., Sudewo, A. H., & Wibowo, A. (2024). Particle Swarm Optimization and GridSearch Optimization on Support Vector Machine Algorithm on Sentiment Analysis Of Donald Trump's Assassination Attempt. *Jurnal Teknik Informatika (Jutif)*, 5(6), 1609–1619. <https://doi.org/10.52436/1.jutif.2024.5.6.2713>
- Rahman, F., Thobroni, A. Y., & Farozdaq, A. T. (2023). Pemaknaan Kembali QS. Al-Hasyr :18 Sebagai Tujuan Utama Pendidikan Islam Yang Adaptif Dalam Menyongsong Generasi Khairu Ummah. *JURNAL KEPENDIDIKAN ISLAM*, 13(1).
- Rama Samudra, M., Marcellina, D., Yulianti, E., Roni Coyanda, J., & Pratiwi Putri, I. (2024). Penerapan Metode Forecasting Dalam Menentukan Prediksi Jumlah Mahasiswa Baru Dengan Menggunakan Single Exponential Smoothing. *JURNAL ILMIAH INFORMATIKA GLOBAL VOLUME*, 15(2), 45–51.
- Ridla, M. A., Azise, N., & Rahman, M. (2023). Perbandingan Model Time Series Forecasting Dalam Memprediksi Jumlah Kedatangan Wisatawan Dan Penumpang Airport. *SIMKOM: Jurnal Sistem Informasi Dan Sistem Komputer*, 8(1), 1–14. <https://doi.org/10.51717/simkom.v8i1.103>

- Safira, A. N., Warsito, B., & Rusgiyono, A. (2023). Analisis Support Vector Regression (SVR) Dengan Algoritma Grid Search Time Series Cross Validation Untuk Prediksi Jumlah Kasus Terkontaminasi Covid-19 di Indonesia. *Jurnal Gaussian*, 11(4), 512–521. <https://doi.org/10.14710/j.gauss.11.4.512-521>
- Sasmi, M., Agustar, A., Wahyuni Syarfi, I., & Hasnah. (2023). DINAMIKA EKONOMI PETANI KARET. *Jurnal Agri Sains*, 7(1), 32–47. <http://ojs.umb-bungo.ac.id/index.php/JAS/index>
- Sihombing, C. V. M., Martha, S., & Huda, N. M. (2022). Analisis Metode Hybrid ARIMA-SVR Pada Indeks Harga Saham Gabungan. *Buletin Ilmiah Math. Stat. Dan Terapannya (Bimaster)*, 11(3), 413–422.
- Solimah, Gusmiati, D. S., & Lasmiyati. (2024). *STATISTIK KARET INDONESIA 2023* (A. S. Nusaliyawati, Tran.; Vol. 17). Badan Pusat Statistik.
- Sri Hertina, Khoirun Nisyak, & Nur Aslamiah Supli. (2021). DAYA SAING KARET ALAM SUMATERA SELATAN DALAM PERDAGANGAN INTERNASIONAL. *Indonesian Journal of International Relations*, 5(2), 241–263. <https://doi.org/10.32787/ijir.v5i2.226>
- Suri, T. N., Rahmanta, & Wibowo, R. P. (2021). Analysis of Affecting Factors on the Natural Rubber Exports Volume in North Sumatera. *Indonesian Journal of Agricultural Research*, 4(1), 58–64. <https://doi.org/10.32734/injar.v4i1.4584>
- Syarifa, L. F., Rahutomo, S., Haris, U., Sahuri, Nugraha, I. S., Alamsyah, A., Agustina, D. S., & Asywadi, H. (2025). An Overview of Indonesian Natural Rubber Industry Performance. *IOP Conference Series: Earth and Environmental Science*, 1526(1). <https://doi.org/10.1088/1755-1315/1526/1/012027>
- Yan, Y., Wang, X., Ren, F., Shao, Z., & Tian, C. (2022). Wind speed prediction using a hybrid model of EEMD and LSTM considering seasonal features. *Energy Reports*, 8, 8965–8980. <https://doi.org/10.1016/j.egyr.2022.07.007>
- Yusuf Andrika, M., & Rahardi, M. (2025). Comparative Study of Linear Regression, SVR, and XGBoost for Stock Price Prediction After a Stock Split. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 9, Number 4). <http://jurnal.polibatam.ac.id/index.php/JAIC>