



FCPO Malaysia Stock Exchange Price Prediction Using Particle Swarm Optimization-Based Support Vector Regression

Prediksi harga FCPO Bursa Malaysia Menggunakan Support Vector Regression Berbasis Particle Swarm Optimization

Fatwa Fatahillah Fatah^{1*}, Roni Andarsyah², Cahyo Prianto³

^{1,2,3}Program Studi Diploma IV Teknik Informatika, Sekolah Vokasi,
Universitas Logistik dan Bisnis Internasional, Indonesia

E-Mail: ¹fatwafatahillah.f@gmail.com, ²roniandarsyah@ulbi.ac.id, ³cahyo@ulbi.ac.id

Received Aug 15th 2025; Revised May 05th 2026; Accepted Jun 15th 2026; Available Online Jun 21th 2026

Corresponding Author: Fatwa Fatahillah Fatah

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Crude Palm Oil (CPO) is a strategic vegetable oil commodity whose price is influenced by global supply and demand dynamics and trade policies. These rapid and unpredictable fluctuations impact the entire supply chain from farmers to the processing industry and policymakers, thus requiring an accurate and adaptive prediction model based on daily market signals. This study builds a Support Vector Regression (SVR) model enhanced with Particle Swarm Optimization (PSO) and compares it with SVR without optimization. The data used in this study include daily palm oil (FCPO) price information from Bursa Malaysia Derivatives from 2020 to 2025. The results show that PSO finds an effective configuration, minimum cost MSE = 0.018675, and PSO-SVR outperforms the default SVR visually and metrically. On the original scale, MAE = 83.939, MAPE = 1.84%, RMSE = 119.881, and $R^2 = 0.9817$ were obtained. These results indicate that PSO-SVR improves prediction performance compared to standard SVR. However, the very high R^2 value should be interpreted with caution, given the volatility of CPO prices and the potential for overfitting. Thus, PSO-SVR can be considered as a supporting approach for CPO price prediction based on daily market data, but still requires periodic validation before being applied in operational decision-making.

Keyword: *Crude Palm Oil, Price Prediction, Support Vector Regression, Particle Swarm Optimization*

Abstrak

*Crude Palm Oil (CPO) merupakan komoditas minyak nabati strategis yang harganya dipengaruhi oleh dinamika penawaran dan permintaan global serta kebijakan perdagangan. Fluktuasi yang cepat dan sulit diprediksi ini berdampak pada seluruh rantai pasok dari petani hingga industri pengolahan dan pembuat kebijakan, sehingga dibutuhkan model prediksi yang akurat dan adaptif berbasis sinyal pasar harian. Penelitian ini membangun model *Support Vector Regression* (SVR) yang ditingkatkan menggunakan *Particle Swarm Optimization* (PSO), serta membandingkannya dengan SVR tanpa optimasi. Data yang digunakan dalam penelitian ini meliputi informasi harga harian minyak sawit (FCPO) di BURSA Malaysia Derivatives dari tahun 2020 hingga 2025. Hasil menunjukkan PSO menemukan konfigurasi yang efektif, dengan biaya minimum MSE = 0,018675, dan PSO-SVR melampaui SVR default, baik secara visual maupun secara metrik. Pada skala asli diperoleh MAE = 83,939, MAPE = 1,84%, RMSE = 119,881, dan $R^2 = 0,9818$. Hasil ini menunjukkan bahwa PSO-SVR mampu meningkatkan kinerja prediksi dibandingkan dengan SVR standar. Namun, nilai R^2 yang sangat tinggi perlu diinterpretasikan secara hati-hati mengingat karakteristik harga CPO yang volatil serta potensi risiko *overfitting*. Dengan demikian, PSO-SVR dapat dipertimbangkan sebagai pendekatan pendukung untuk prediksi harga CPO berbasis data pasar harian, dengan tetap memerlukan validasi berkala sebelum diterapkan dalam pengambilan keputusan operasional.*

Kata Kunci: *Crude Palm Oil, Prediksi Harga, Support Vector Regression, Particle Swarm Optimization*

1. PENDAHULUAN

Crude Palm Oil (CPO) merupakan minyak sawit mentah hasil pengambilan daging buah kelapa sawit yang banyak digunakan sebagai feedstock industri makanan olahan, kosmetik, sabun, deterjen, dan berbagai produk pembersih [1]. Sebagai komoditas minyak nabati strategis, harganya dipengaruhi oleh permintaan dan penawaran global, kebijakan perdagangan, perkembangan energi terbarukan serta kondisi lingkungan dan



cuaca di wilayah produksi. Variasi faktor tersebut sering memicu perubahan harga yang cepat dan sulit diprediksi, sehingga menjadi tantangan bagi pelaku di seluruh rantai pasok, mulai dari petani yang membutuhkan kepastian pendapatan hingga industri pengolahan dan pembuat kebijakan [2]. Bagi Indonesia dan Malaysia yang menjadi produsen utama, fluktuasi harga berdampak strategis pada perekonomian nasional, daya saing ekspor, dan kesejahteraan jutaan tenaga kerja, sehingga diperlukan prediksi harga yang akurat dan adaptif agar perencanaan produksi, distribusi, dan manajemen risiko menjadi lebih efektif [3]. Pasar komoditas pertanian sendiri cenderung tidak stabil karena penawaran dan permintaan yang kaku, dan dalam konteks minyak sawit tersedia kontrak berjangka di Bursa Malaysia [4] yang banyak dimanfaatkan untuk mengelola fluktuasi. Jika harga kontrak berjangka atau harga pasar harian dapat diperkirakan dengan baik, petani penyuling dan distributor dapat merencanakan strategi lindung nilai untuk waktu pembelian serta mengatur pasokan dengan lebih percaya diri. Dengan demikian, model prediksi berbasis sinyal pasar harian yang akurat dan tangkas tidak hanya bermanfaat untuk pemantauan operasional, tetapi juga relevan sebagai masukan bagi perencanaan pembelian kontrak berjangka dan pengelolaan risiko harga sepanjang rantai pasok [5].

Pada horizon harian, banyak penggerak makro tersebut termanifestasi secara implisit di dalam jejak historis harga. Informasi pasar yang langsung teramat, seperti harga pembukaan, tertinggi, terendah, penutupan, volume, dan persentase perubahan, menjadi dasar yang memadai untuk membangun model prediksi operasional. Penelitian ini karena itu menitikberatkan pada pemodelan berbasis sinyal pasar yang diperkaya dengan fitur temporal sederhana berupa lag dan fitur kalender. Kerangka ini diimplementasikan menggunakan *Support Vector Regression* dengan penentuan *hyperparameter* yang dioptimasi melalui *Particle Swarm Optimization*. Kajian dilakukan pada data tahun 2020 sampai 2025 dengan keluaran utama berupa perbandingan kinerja model dasar tanpa optimasi dan model hasil optimasi, serta penerapan model terpilih untuk melakukan peramalan pada periode mendatang sebagai dukungan pengambilan keputusan.

Support Vector Regression banyak digunakan untuk memprediksi harga komoditas karena mampu menangani data berdimensi tinggi dan menghasilkan generalisasi yang baik [6]. Kinerja SVR sangat dipengaruhi oleh pemilihan *hyperparameter* yaitu C sebagai pengendali regularisasi, ϵ sebagai margin kesalahan, dan γ sebagai parameter kernel. Kombinasi yang tidak tepat dapat membuat model terlalu kaku sehingga gagal mengikuti perubahan tren atau sebaliknya terlalu mengikuti *noise* sehingga generalisasi menurun [7]. Karena itu, diperlukan prosedur optimasi yang sistematis agar konfigurasi *hyperparameter* yang diperoleh mampu menyeimbangkan bias dan varians serta stabil secara numerik.

Studi sebelumnya, [5] telah menunjukkan bahwa pendekatan optimasi seperti *simulated annealing* dapat meningkatkan kinerja SVR pada data harga minyak sawit. Pada saat yang sama, *Particle Swarm Optimization* banyak digunakan untuk penyetelan *hyperparameter* karena mekanismenya sederhana, ruang jelajahnya luas, dan kecepatan konvergensinya baik pada berbagai kasus regresi. Penelitian ini membangun model prediksi harga minyak sawit berbasis SVR yang dioptimasi dengan PSO lalu mengujinya pada data yang lebih terkini, yaitu periode tahun 2020 sampai 2025. Pendekatan ini diharapkan menghasilkan model prediksi yang tidak hanya akurat tetapi juga responsif terhadap perubahan tren harga minyak sawit di masa kini.

2. STUDI LITERATUR


Berbagai studi menunjukkan kemajuan pesat dalam pemodelan harga *crude palm oil* yang berfokus pada penyetelan *hyperparameter*, *deep learning* berbasis dekomposisi, serta arsitektur jaringan yang dirancang khusus, namun masih menyisakan celah riset penting. Pertama, pendekatan metaheuristik untuk tuning *hyperparameter* pada SVR terbukti sangat efektif, misalnya SA-SVR yang memprediksi harga penutupan FCPO dengan MAPE 2.10% dan R^2 98.13% sehingga jauh lebih akurat daripada SVR tanpa tuning [5]. Kedua, keluarga model *deep learning* berbasis dekomposisi sinyal mengungguli LSTM tunggal karena mampu memisahkan pola frekuensi dan mereduksi noise. Contohnya, GA-optimized VMD-LSTM pada komoditas palm oil mencatat MAPE 3.47% serta directional accuracy 72.73%, sekaligus menurunkan RMSE dibandingkan baseline. Bukti tambahan menunjukkan bahwa Dstat meningkat dari 36.36% menjadi 72.73% untuk palm oil, dan seluruh hibrida unggul secara signifikan pada uji DM pada horizon satu tahun [8]. Ketiga, rancangan jaringan yang menambang aturan logis juga relevan untuk mengklasifikasi arah pergerakan harga dan menunjukkan akurasi tinggi, misalnya RBFNN-2SATRA yang mencapai akurasi 90.476% pada data harga palm oil Malaysia, sehingga melampaui varian pembandingnya, yaitu 85.71% dan 76.19% [9].

Di sisi penggabungan *multi-source*, kerangka MHDA berbasis HMGMM memperlihatkan bahwa penambahan fitur berita dan sentimen serta pengayaan representasi data meningkatkan akurasi model konvensional, misalnya SVM yang semula 49.22% dan Random Forest 56.84% menjadi lebih baik setelah integrasi fitur, dengan kenaikan akurasi yang tercatat sebesar 3.89%, 5.64%, 22.46%, dan 6.67% pada konfigurasi yang diuji [10]. Pemetaan ini menegaskan bahwa tuning metaheuristik pada SVR, hibrida dekomposisi plus LSTM, serta jaringan berbasis aturan merupakan tiga lintasan utama yang saling melengkapi dalam meningkatkan akurasi level dan arah harga palm oil, termasuk bukti penurunan MAPE puluhan persen dan peningkatan directional accuracy ke kisaran tujuh puluh hingga seratus persen pada beberapa *dataset* [8]. Meski demikian, terdapat beberapa gap yang masih terbuka, antara lain keterbatasan komputasi yang memaksa

penggunaan porsi latih yang sangat kecil pada sebagian studi, sehingga dapat membatasi generalisasi model, seperti SA-SVR yang akhirnya hanya melatih 10% data untuk mengatasi kendala memori [5].

3. METODOLOGI PENELITIAN

Tahapan penelitian yang dilakukan mencakup pengumpulan data harga minyak sawit, kemudian *preprocessing* data, *training-testing* model, evaluasi dan analisis. Tahapan alur penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Diagram Alur Tahapan Penelitian

3.1. Data Collection

Pemilihan sumber data yang kredibel dan relevan merupakan aspek penting dalam penelitian kuantitatif, khususnya dalam pemodelan prediktif komoditas dan keuangan. Kualitas data input menentukan validitas hasil akhir, karena model tidak dapat menghasilkan prediksi yang akurat dari data yang cacat atau tidak representatif [11] [12]. Oleh karena itu, data penelitian dikumpulkan secara sistematis dari *investing.com*, yaitu penyedia data historis pasar keuangan.

Data dikumpulkan dalam bentuk historis harian selama rentang waktu penelitian untuk menangkap tren dan volatilitas pasar. Variabel utama yang dikumpulkan dari sumber tersebut meliputi: harga buka (*Open*), harga tinggi (*High*), harga rendah (*Low*), harga tutup (*Close*), dan volume perdagangan (*Volume*). Selain itu, data perubahan persentase harian (*Change %*) juga diekstraksi untuk analisis volatilitas. Data publik tersebut diunduh dalam format terstruktur, seperti CSV, sesuai dengan ketentuan penggunaan situs.

Pemilihan *dataset* harga historis minyak kelapa sawit didasarkan pada signifikansi komoditas ini dalam perekonomian global dan regional. Sebagai salah satu komoditas pertanian utama dunia, pergerakan harga minyak kelapa sawit memiliki dampak ekonomi yang luas, terutama bagi negara produsen utama seperti Indonesia dan Malaysia [13]. Sifat data deret waktu yang nonlinier dan dinamis menjadikannya subjek yang menantang sekaligus ideal untuk penerapan teknik-teknik *machine learning* tingkat lanjut seperti *Support Vector Regression* dan model hibrida [14].

Data ini juga digunakan dalam penelitian oleh [5] yang mengusulkan model hibrida optimasi *Simulated Annealing* pada *Support Vector Regression* (SA-SVR) untuk memprediksi harga minyak kelapa sawit (FCPO). Penelitian ini memanfaatkan data historis harga CPO yang diperoleh dari Bursa Malaysia dan menunjukkan bahwa penerapan SA pada SVR dapat meningkatkan akurasi prediksi dengan mengoptimalkan parameter model. Hasil eksperimen menunjukkan bahwa model SA-SVR lebih efektif dibandingkan dengan SVR dengan pengaturan parameter default, meskipun hanya menggunakan 10% data pelatihan karena keterbatasan memori. Berdasarkan uraian tersebut, *dataset* harga historis minyak kelapa sawit dari *investing.com* dinilai relevan untuk digunakan pada tahap data *pre-processing*, pelatihan, dan pengujian model prediksi.

3.2. Data Preprocessing

Data preprocessing merupakan tahap penting untuk mengubah data mentah menjadi data yang bersih, terstruktur, dan siap digunakan dalam analisis atau pemodelan *machine learning* [15]. Pendekatan metodologis dalam *data pre-processing* pada penelitian ini difokuskan pada 4 komponen utama: *Data Cleaning*, *Feature*

Engineering, Data Splitting, dan Transformation. *Data cleaning* dilakukan untuk mengidentifikasi dan menangani missing values agar integritas dan konsistensi data tetap terjaga [16]. *Feature engineering* dilakukan dengan mengekstraksi atau membentuk fitur baru agar data memiliki representasi yang lebih informatif bagi model [17]. Dalam penelitian ini, fitur-fitur berbasis tanggal dan *lag* dari variabel harga historis dibuat untuk menangkap tren temporal dan ketergantungan sekuensial pada data. *Data splitting* dilakukan dengan membagi *dataset* menjadi data pelatihan dan data pengujian untuk mengevaluasi kemampuan generalisasi model serta mengurangi risiko *overfitting* [18]. Untuk data deret waktu (*time-series*), pembagian data harus dilakukan secara kronologis tanpa pengacakan (*shuffling*) untuk menjaga dependensi temporal [19]. *Transformation data* dilakukan untuk menyeragamkan skala fitur numerik agar tidak ada variabel yang mendominasi proses pembelajaran, terutama pada algoritma yang sensitif terhadap skala seperti *Support Vector Machines* (SVM) [20]. Teknik yang umum digunakan meliputi normalisasi ke rentang [0, 1] dan standarisasi dengan rata-rata 0 serta standar deviasi 1 [21]. Secara ringkas, keempat komponen metodologis ini membentuk alur kerja yang sistematis untuk menyiapkan data. Pendekatan ini memastikan bahwa data yang digunakan untuk pemodelan tidak hanya bersih secara teknis, tetapi juga optimal secara informasional dan prosedural.

3.3. Training dan Testing Model

Pemilihan model regresi merupakan tahap penting dalam penelitian prediktif untuk memetakan hubungan antara variabel input dan variabel output numerik [22]. *Support Vector Regression* (SVR) dipilih karena mampu menangani pola data *nonlinier* melalui prinsip maksimalisasi margin. Namun, performa SVR sangat sensitif terhadap pemilihan *hyperparameter*-nya [23]. Oleh karena itu, pendekatan hibridisasi dengan *Particle Swarm Optimization* (PSO) digunakan untuk mengoptimalkan *hyperparameter* SVR agar akurasi dan kemampuan generalisasi model meningkat.

SVR telah banyak digunakan dalam berbagai studi terdahulu untuk pemodelan regresi karena kemampuannya yang terbukti andal dalam menangani data nonlinier serta menunjukkan kemampuan generalisasi yang baik, sebagaimana diterapkan dalam penelitian oleh [24], [25], [26], [27], [28]. Selain itu, integrasi PSO sebagai teknik optimisasi *hyperparameter* SVR telah terbukti secara empiris mampu meningkatkan kinerja prediksi, seperti yang dilaporkan dalam kajian oleh [25], [29], [9], [30], karena kemampuannya dalam mencari solusi optimal secara efisien di ruang pencarian yang kompleks.

Prinsip kerja SVR adalah menemukan *hyperplane* yang optimal dengan meminimalkan kesalahan prediksi dalam batas toleransi tertentu. Hal ini dicapai melalui minimisasi fungsi objektif yang mempertimbangkan ϵ -insensitive loss, di mana kesalahan dalam rentang $\pm\epsilon$ dari nilai aktual diabaikan [31]. Formulasi matematis dari fungsi objektif SVR ditunjukkan pada Persamaan 1.

$$\text{Min} = \frac{1}{2} \|w\|^2 C \sum_{i=1}^N (\delta_i + \delta_i^*) \quad (1)$$

Di mana w adalah vektor bobot yang menentukan orientasi *hyperplane*, C adalah parameter penalti yang mengatur keseimbangan antara kompleksitas model dan kesalahan pelatihan, serta δ_i dan δ_i^* adalah *slack variables* yang mengukur deviasi di luar batas toleransi ϵ . Untuk menangani data non-linear, SVR memanfaatkan fungsi kernel (seperti *Radial Basis Function* atau RBF, linear, atau polinomial) untuk memetakan data ke ruang fitur berdimensi lebih tinggi [32].

Untuk menemukan kombinasi *hyperparameter* SVR yang optimal (C , γ , dan ϵ), PSO digunakan sebagai algoritma optimasi. PSO adalah algoritma metaheuristik berbasis populasi yang mensimulasikan perilaku sosial kawanan dalam mencari sumber makanan. Setiap "partikel" dalam kawanan merepresentasikan satu solusi calon, yaitu satu set *hyperparameter* SVR. Posisi partikel diperbarui secara iteratif berdasarkan dua informasi kunci: posisi terbaik yang pernah dicapainya secara pribadi (*pbest*) dan posisi terbaik yang pernah dicapai oleh seluruh kawanan secara global (*gbest*) [33]. Rumus pembaruan kecepatan dan posisi partikel ditunjukkan pada Persamaan 2.

$$\begin{aligned} V_{id} &= \omega V_{id} + C_1 \text{random}(0,1)(P_{id} - X_{id}) + C_2 \text{random}(0,1)(P_{gd} - X_{id}) \\ X_{id} &= X_{id} + V_{id} \end{aligned} \quad (2)$$

Di sini, V_{id} adalah kecepatan partikel, X_{id} adalah posisinya, ω adalah faktor inersia, P_{id} adalah dimensi individu dari solusi terbaik partikel ke- i , P_{gd} adalah dimensi ke- d solusi global optimal, C_1 dan C_2 adalah koefisien pembelajaran kognitif dan sosial, serta random adalah bilangan acak untuk stokastisitas. Dalam alur integrasinya, PSO mencari kombinasi *hyperparameter* SVR yang mampu meminimalkan fungsi objektif yang kemudian digunakan untuk melatih model SVR final [33].

Berdasarkan studi literatur dan temuan penelitian sebelumnya, kombinasi PSO-SVR diadopsi dalam metodologi ini karena menawarkan pendekatan yang sistematis dan cerdas untuk mengoptimasi model. Pendekatan hibrida ini diharapkan mampu mengatasi keterbatasan SVR tradisional yang sering kali bergantung

pada proses *tuning* manual atau *grid search* yang kurang efisien, sehingga menghasilkan model prediksi dengan akurasi dan kemampuan generalisasi yang lebih baik.

3.4. Evaluasi Model

Evaluasi kinerja model merupakan tahapan kritis dalam siklus pengembangan model prediktif, yang berfungsi untuk mengukur akurasi dan ketepatan prediksi secara objektif [34]. Di penelitian ini, empat metrik standar industri dan akademik digunakan untuk mengevaluasi kinerja model regresi: *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan *Coefficient of Determination* (R^2).

Mean Absolute Error (MAE) mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual. Metrik ini memberikan gambaran langsung mengenai besaran rata-rata kesalahan prediksi dalam unit yang sama dengan variabel target. Karena tidak mengkuadratkan kesalahan, MAE lebih robust terhadap nilai pencilan (*outliers*) [35], [36], [37]. Rumus matematis ditunjukkan pada Persamaan 3.

$$MAE = \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Root Mean Squared Error (RMSE) adalah akar kuadrat dari *Mean Squared Error* (MSE). Keunggulan utamanya adalah hasilnya kembali ke unit yang sama dengan variabel target, sehingga lebih mudah diinterpretasikan dibandingkan dengan MSE. Seperti MSE, RMSE juga memberikan penalti yang signifikan terhadap kesalahan yang besar [35], [37].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Mean Absolute Percentage Error (MAPE) mengevaluasi akurasi model regresi, terutama ketika fokusnya pada kesalahan relatif, alih-alih kesalahan absolut. MAPE menyatakan kesalahan prediksi sebagai persentase, sehingga mudah digunakan untuk membandingkan kinerja model di berbagai skala [37]. Secara matematis ditunjukkan pada Persamaan 5.

$$MAPE = \frac{1}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\max(\varepsilon, |y_i|)} \right| \quad (5)$$

Coefficient of Determination (R^2) mengukur proporsi varians pada variabel dependen yang dapat diprediksi dari variabel independen. Nilai R^2 berkisar antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan kecocokan model yang lebih baik. Nilai 1 menandakan prediksi yang sempurna, sedangkan nilai 0 menunjukkan bahwa model tidak lebih baik daripada sekadar memprediksi nilai rata-rata dari data target [37].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

Dalam metodologi ini, keempat metrik tersebut dihitung secara terpisah untuk model SVR standar dan model hibrida PSO-SVR pada data pengujian. Pendekatan ini memastikan bahwa perbandingan kinerja antara kedua model dilakukan secara adil, objektif, dan komprehensif.

4. HASIL DAN PEMBAHASAN

4.1. Data Collection

Bagian ini mendeskripsikan karakteristik *dataset* harga harian CPO periode 2020–2025 yang digunakan sebagai dasar pemodelan. Deskripsi detail *dataset* yang telah dikumpulkan menunjukkan bahwa ia terdiri dari lebih dari 1.342 observasi harian yang mencakup rentang waktu hampir 5 tahun. Analisis awal mengidentifikasi adanya beberapa data yang hilang (*missing values*), terutama pada variabel volume perdagangan, yang umum terjadi karena pasar berlibur. Statistik deskriptif dasar, yang ringkasannya disajikan dalam Tabel 1, menunjukkan rentang nilai yang luas pada variabel harga, yang mencerminkan volatilitas pasar selama periode pengamatan. Informasi ini krusial untuk merancang strategi *data cleaning* dan transformasi yang tepat pada tahap selanjutnya.

Tabel 1. Fitur data FCPO Bursa Malaysia

Fitur	Deskripsi
Date	Tanggal perdagangan saat data dicatat
Open	Harga saat pasar dibuka

Fitur	Deskripsi
Close (target)	Harga saat pasar ditutup
High	Harga tertinggi yang dicapai dalam satu hari perdagangan
Low	Harga terendah yang dicapai dalam satu hari perdagangan
Volume	Total volume perdagangan dalam satu hari perdagangan
Percentage Change	Selisih persentase antara harga penutupan hari perdagangan saat ini dan sebelumnya

4.2. Data Preprocessing

Pada bagian ini, disajikan implementasi rinci dari keempat tahapan *data pre-processing* yang diterapkan pada *dataset* historis harga *Crude Palm Oil* (CPO) untuk tujuan prediksi harga penutupan (*Close Price*). *Dataset* awal mencakup data harian dari Januari 2020 hingga Juli 2025, yang terdiri dari variabel *Open*, *High*, *Low*, *Close*, *Volume*, dan *Percentage Change*. Tujuan dari pra-pemrosesan ini adalah menyiapkan *dataset* berkualitas tinggi sebagai input untuk model prediksi berbasis *Support Vector Regression* (SVR).

Proses dimulai dengan inspeksi awal pada *dataset* untuk mengidentifikasi data yang hilang. Dari analisis awal, ditemukan bahwa *dataset* terdiri dari 1342 baris data. Pemeriksaan nilai nol (*null values*) menunjukkan bahwa sebagian besar kolom tidak memiliki data yang hilang, kecuali pada kolom *Volume* yang teridentifikasi memiliki 33 nilai yang hilang. Jumlah ini merepresentasikan sekitar 2,46% dari total data, yaitu proporsi yang relatif kecil. Keputusan teknis yang diambil adalah menghapus seluruh baris yang mengandung nilai yang hilang. Metode ini dipilih karena dianggap tidak akan secara signifikan mengurangi ukuran maupun representasi *dataset* secara keseluruhan. Setelah proses pembersihan, jumlah data berkurang menjadi 1309 baris, semuanya lengkap dan siap untuk tahap selanjutnya. Statistik deskriptif data sebelum dan sesudah pembersihan dirangkum dalam tabel 2 untuk menunjukkan perbandingan karakteristik data.

Tabel 2. Perbandingan karakteristik data

Karakteristik	Sebelum Pembersihan	Setelah Pembersihan
Jumlah Baris	1342	1309
Nilai Hilang (Kolom Volume)	33	0
Persentase Nilai Hilang	2.46%	0%

Setelah data dibersihkan, dilakukan rekayasa fitur untuk mengekstrak informasi temporal dan dependensi historis yang relevan untuk prediksi harga. Pertama, fitur-fitur yang terkait dengan tanggal diekstraksi dari kolom *Date*. Penambahan fitur ini bertujuan agar model dapat mempelajari pola musiman atau siklus tahunan yang mungkin ada. Kedua, dibuat fitur *lag* untuk variabel-variabel kunci dari satu periode sebelumnya ($t-1$) merepresentasikan kondisi pasar pada hari sebelumnya dan secara teoretis memiliki pengaruh kuat terhadap harga pembukaan dan penutupan pada hari ini. Hasil dari tahapan ini adalah *dataset* yang diperkaya dengan total 13 fitur prediktor.

Dataset yang sudah diperkaya kemudian dibagi menjadi himpunan data pelatihan dan himpunan data pengujian. Mengingat sifat data sebagai deret waktu, pembagian dilakukan secara kronologis untuk menjaga urutan temporal. Data dibagi dengan rasio 10% untuk data pelatihan dan 90% untuk data pengujian. Pilihan rasio ini didasarkan pada skenario pemodelan, di mana model dilatih pada periode awal yang lebih singkat, kemudian diuji kemampuannya dalam memprediksi periode yang jauh lebih panjang di masa depan. Data pelatihan terdiri dari 130 baris pada 130 baris pertama, sedangkan 1179 baris sisanya dialokasikan sebagai data pengujian. Proses pembagian ini dilakukan tanpa pengacakan untuk memastikan bahwa data pengujian benar-benar merupakan data "masa depan" yang tidak diketahui oleh model selama fase pelatihan. Pembagian data yang merangkum jumlah sampel untuk setiap set disajikan dalam Tabel 3.

Tabel 3. Pembagian data training dan testing

Himpunan Data	Jumlah Baris
Data Pelatihan	130
Data Pengujian	1179
Total	1309

Tahap selanjutnya adalah transformasi data. Transformasi ini diterapkan secara terpisah pada fitur (X) dan variabel target (Y) untuk menghindari kebocoran data. *Scaler* dilatih (*fit*) hanya pada data pelatihan, kemudian transformasi diterapkan pada data pelatihan dan pengujian. Proses ini bertujuan untuk menstandarisasi rentang nilai fitur-fitur numerik dan mengubah distribusinya agar lebih mendekati distribusi normal. Hasilnya, data fitur dan target diubah ke dalam skala yang seragam dengan rata-rata mendekati nol dan standar deviasi satu.

4.3. Training dan Testing

Proses pelatihan dimulai dengan membangun model SVR standar menggunakan parameter awal yang ditentukan, yang berfungsi sebagai model pembanding atau *baseline*. Selanjutnya, proses pelatihan model PSO-SVR diinisiasi. Dalam tahap ini, algoritma PSO secara iteratif mengevaluasi performa SVR dengan berbagai kombinasi *hyperparameter*. Setiap partikel dalam *swarm* merepresentasikan satu konfigurasi SVR, dan kinerjanya diukur. Selama 10 iterasi, partikel-partikel menyesuaikan posisi mereka menuju area dalam ruang pencarian yang menjanjikan, dipandu oleh nilai *pbest* dan *gbest*. Setelah proses konvergensi, PSO menghasilkan satu set *hyperparameter* yang dianggap optimal. Parameter hasil optimisasi PSO yang optimal, yang mencakup nilai terbaik untuk C , γ , dan ϵ , dirangkum secara rinci dalam Tabel 4.


Tabel 4. Parameter Optimal Hasil Optimisasi PSO untuk Model SVR

Parameter	Hasil Optimal
C	1998
γ	$4,2570441727 \times 10^{-5}$
ϵ	0,005598274

Setelah kedua model dilatih, keduanya digunakan untuk memprediksi data pengujian. Perbandingan antara nilai aktual dan hasil prediksi untuk masing-masing model ditampilkan secara visual pada Gambar 2 (SVR) dan Gambar 3 (PSO-SVR).



Gambar 2. Perbandingan nilai aktual dan prediksi SVR



Gambar 3. Perbandingan nilai aktual dan prediksi PSO-SVR

Visualisasi ini menggambarkan sejauh mana garis prediksi dari setiap model mampu mengikuti pola dan dinamika data aktual. Dari analisis terhadap grafik tersebut, terlihat bahwa model PSO-SVR menunjukkan ketepatan *tracking* tren yang lebih tinggi. Deviasinya, terutama pada saat terjadi fluktuasi ekstrem, cenderung lebih kecil dibandingkan model SVR standar, dan prediksinya menunjukkan konsistensi yang lebih baik secara keseluruhan. Hal ini dapat diatribusikan pada kemampuan PSO dalam menemukan konfigurasi parameter yang lebih seimbang dan optimal, yang sulit dicapai melalui pendekatan tradisional.

4.4. Evaluasi

Hasil evaluasi untuk model SVR standar menunjukkan kinerja sebagai berikut. Nilai MAE tercatat sebesar 1739.36, yang mengindikasikan rata-rata kesalahan absolut prediksi. Nilai MAPE sebesar 0.3836 dan RMSE sebesar 1965.18 menyoroti besaran kesalahan kuadratik, dengan nilai yang lebih tinggi menandakan deviasi prediksi yang lebih besar. Terakhir, nilai R^2 sebesar -3.89 memberikan gambaran tentang seberapa baik model dapat menjelaskan variasi dalam data.

Selanjutnya, hasil evaluasi model PSO-SVR menunjukkan performa yang telah dioptimalkan. Nilai MAE untuk model ini adalah 83.93. Nilai MAPE tercatat sebesar 0.018, dengan RMSE sebesar 119.88. Nilai-nilai kesalahan ini memberikan ukuran kuantitatif dari akurasi model setelah *hyperparameter*-nya disesuaikan oleh algoritma PSO. Kemampuan model dalam menjelaskan data diukur dengan nilai R^2 sebesar 0.9817. Untuk memfasilitasi analisis, seluruh metrik ini dirangkum secara sistematis dalam Tabel 5.

Tabel 5. Metrik Evaluasi Model SVR dan PSO-SVR

Model	MAE	MAPE	RMSE	R^2
SVR	1739.36	0.3836	1965.18	-3.89
PSO-SVR	83.93	0.018	119.88	0.9817

Nilai R^2 sebesar 0.9817 pada model PSO-SVR menunjukkan bahwa model mampu menjelaskan sebagian besar variasi data pada skenario pengujian yang digunakan. Meskipun demikian, nilai R^2 yang sangat tinggi pada data harga komoditas perlu dianalisis secara hati-hati karena terdapat kemungkinan model menangkap pola jangka pendek atau noise pada data, bukan hanya hubungan yang stabil. Risiko overfitting tetap perlu dipertimbangkan, terutama ketika model menunjukkan selisih performa yang sangat besar dibandingkan dengan SVR standar. Untuk mengurangi risiko tersebut, proses pelatihan dan pengujian dilakukan dengan mempertahankan urutan kronologis data deret waktu, tanpa pengacakan data, serta mengevaluasi model menggunakan beberapa metrik, yaitu MAE, MAPE, RMSE, dan R^2 . Namun, validasi tambahan seperti walk-forward validation atau pengujian pada periode pasar yang berbeda tetap diperlukan untuk memastikan kemampuan generalisasi model.

Penyajian hasil numerik ini menunjukkan bahwa optimasi PSO meningkatkan kinerja model SVR berdasarkan metrik evaluasi yang digunakan. Namun, nilai R^2 PSO-SVR yang sangat tinggi perlu diinterpretasikan secara hati-hati, terutama karena data harga komoditas dan data finansial umumnya bersifat volatil, nonlinier, dan rentan terhadap perubahan pola pasar.

4.5. Analisis

Untuk memperjelas perbandingan, kinerja prediksi kedua model disajikan secara visual pada Gambar 4. Grafik ini memplot tiga garis secara simultan pada satu sumbu waktu: (1) nilai data aktual, (2) nilai prediksi dari model SVR, dan (3) nilai prediksi dari model PSO-SVR. Dari visualisasi ini, terlihat jelas bahwa garis prediksi yang dihasilkan oleh model PSO-SVR menunjukkan tingkat kecocokan yang jauh lebih tinggi dibandingkan dengan garis nilai aktual. Model PSO-SVR mampu mengikuti fluktuasi yang tajam dan menangkap titik-titik balik (*turning points*) pasar dengan lebih akurat, sementara garis prediksi dari model SVR cenderung lebih datar dan gagal merespons dinamika data yang signifikan.



Gambar 4. Grafik Perbandingan Prediksi SVR dan PSO-SVR terhadap Nilai Aktual

Temuan visual ini sepenuhnya didukung oleh hasil metrik evaluasi. Nilai RMSE yang secara signifikan lebih rendah dan nilai R^2 yang mendekati 1.0 pada model PSO-SVR secara numerik mengonfirmasi apa yang terlihat secara visual: optimasi *hyperparameter* melalui PSO berhasil menekan rata-rata kesalahan prediksi

secara drastis dan meningkatkan kemampuan model dalam menjelaskan variabilitas data. Peningkatan kinerja ini dapat diatribusikan pada kemampuan PSO sebagai algoritma pencarian global yang efektif. Berbeda dengan metode *grid search* atau *tuning* manual yang cakupannya terbatas, PSO mampu menjelajahi ruang parameter yang luas dan kompleks untuk menemukan kombinasi *hyperparameter* (C , γ , ϵ) yang mendekati optimal, sehingga menghasilkan model SVR dengan fungsi pemetaan yang jauh lebih presisi.

4.6. Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Pertama, model yang dikembangkan hanya menggunakan data historis harga, volume, dan perubahan harian, sehingga belum memasukkan faktor eksternal yang dapat memengaruhi harga CPO, seperti kebijakan ekspor-impor, nilai tukar, harga minyak mentah, kondisi cuaca, geopolitik, serta dinamika permintaan dan penawaran global. Kedua, data yang digunakan berasal dari satu sumber, sehingga masih terdapat kemungkinan bias atau perbedaan kualitas data dibandingkan dengan sumber pasar lainnya. Ketiga, meskipun model PSO-SVR menghasilkan nilai R^2 yang tinggi, performa tersebut belum menjamin bahwa model akan memiliki akurasi yang sama pada kondisi pasar yang berbeda, terutama ketika terjadi shock pasar atau perubahan struktural.

Dari sisi implementasi, model ini sebaiknya digunakan sebagai alat bantu analisis, bukan sebagai satu-satunya dasar pengambilan keputusan. Prediksi harga CPO memiliki risiko ketidakpastian karena pasar komoditas dipengaruhi oleh banyak faktor eksternal yang tidak sepenuhnya tercermin dalam data historis. Oleh karena itu, penerapan model membutuhkan evaluasi berkala, pembaruan data, dan pengujian ulang agar kemampuan generalisasi model tetap terjaga.

5. KESIMPULAN

Penelitian ini mengembangkan dan membandingkan kinerja model prediksi harga komoditas berbasis *Support Vector Regression* (SVR) dengan pendekatan hibrida PSO-SVR yang mengintegrasikan *Particle Swarm Optimization* untuk optimasi *hyperparameter*, melalui alur kerja yang komprehensif mencakup pra-pemrosesan data, pelatihan model, dan evaluasi, hasil evaluasi menunjukkan bahwa model hibrida PSO-SVR memberikan kinerja yang lebih baik dibandingkan SVR standar berdasarkan metrik yang digunakan, dengan penurunan drastis pada RMSE dari 1965.18 (SVR) menjadi 119.88 (PSO-SVR) dan peningkatan nilai R^2 dari -3.89 menjadi 0.9817, yang mengindikasikan bahwa model mampu menangkap pola data pada periode pengujian yang digunakan, sebagaimana dikonfirmasi oleh analisis visual, keberhasilan ini menegaskan efektivitas PSO dalam menemukan kombinasi *hyperparameter* optimal yang meningkatkan generalisasi model, sehingga PSO-SVR berpotensi digunakan sebagai pendekatan pendukung dalam prediksi harga CPO, dengan tetap memperhatikan validasi berkala dan kondisi pasar yang berubah, meskipun dengan beban komputasi yang lebih besar, sementara rekomendasi ke depan mencakup eksplorasi algoritma optimasi lain dan penerapan pada domain serta dataset yang lebih kompleks guna memperluas kontribusi empiris dan pengembangan model hibrida yang lebih adaptif dan andal. Meskipun demikian, penelitian ini memiliki beberapa keterbatasan. Model hanya menggunakan data historis berbasis harga dan volume, sehingga belum memasukkan faktor eksternal seperti kebijakan perdagangan, nilai tukar, harga minyak mentah, kondisi cuaca, geopolitik, serta dinamika permintaan dan penawaran global. Selain itu, nilai R^2 yang sangat tinggi perlu ditafsirkan secara hati-hati karena tetap ada risiko *overfitting* pada data finansial yang volatil. Oleh karena itu, model sebaiknya tidak digunakan sebagai satu-satunya dasar pengambilan keputusan, melainkan sebagai alat bantu analisis yang perlu divalidasi dan diperbarui secara berkala.

REFERENSI

- [1] V. R. Hasibuan, N. Aini, F. Febriyanti, and S. A. A. Pane, "The Effect Of Additional Detergent In Crude Palm Oil In The Process Of Separation Stearin," in *Journal of Physics: Conference Series*, Institute of Physics Publishing, Mar. 2018. doi: 10.1088/1742-6596/970/1/012020.
- [2] I. Hannoeriadi A., H. Siregar, and A. Asmara, "The Production of Food Commodities in Indonesia: Climate Change and Other Determinants," *Jurnal AGRISEP: Kajian Masalah Sosial Ekonomi Pertanian dan Agribisnis*, pp. 317–330, Sep. 2022, doi: 10.31186/jagrisep.21.2.317-330.
- [3] M. A. M. Isa et al., "Crude Palm Oil Price Fluctuation in Malaysia," *International Journal of Academic Research in Business and Social Sciences*, vol. 10, no. 5, May 2020, doi: 10.6007/ijarbss/v10-i5/7319.
- [4] BURSA Malaysia, "Crude palm oil futures (FCPO)." Accessed: Aug. 14, 2025. [Online]. Available: https://www.bursamalaysia.com/trade/our_products_services/derivatives/commodity_derivatives/crud_e_palm_oil_futures
- [5] C. W. Goh, J. Chai, A. Rahman, and W. E. Ong, "CRUDE PALM OIL PRICE PREDICTION USING SIMULATED ANNEALING-BASED SUPPORT VECTOR REGRESSION (SA-SVR)," *Asian Academy of Management Journal of Accounting and Finance*, vol. 20, no. 1, pp. 305–333, Jun. 2024, doi: 10.21315/aamjaf2024.20.1.10.

- [6] X. J. He, "Crude Oil Prices Forecasting: Time Series vs. SVR Models," *Journal of International Technology and Information Management*, vol. 27, no. 2, pp. 25–42, Dec. 2018, doi: 10.58729/1941-6679.1358.
- [7] X. Wang, C. Yang, B. Qin, and W. Gui, "Parameter selection of support vector regression based on hybrid optimization algorithm and its application," 2005.
- [8] K. Choudhary, G. K. Jha, R. Jaiswal, and R. R. Kumar, "A genetic algorithm optimized hybrid model for agricultural price forecasting based on VMD and LSTM network," *Sci Rep*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-94173-0.
- [9] S. A. S. Alzaeemi and S. Sathasivam, "Examining the Forecasting Movement of Palm Oil Price Using RBFNN-2SATRA Metaheuristic Algorithms for Logic Mining," *IEEE Access*, vol. 9, pp. 22542–22557, 2021, doi: 10.1109/ACCESS.2021.3054816.
- [10] L. Chai, H. Xu, Z. Luo, and S. Li, "A multi-source heterogeneous data analytic method for future price fluctuation prediction," *Neurocomputing*, vol. 418, pp. 11–20, Dec. 2020, doi: 10.1016/j.neucom.2020.07.073.
- [11] A. Ampountolas, "Enhancing Forecasting Accuracy in Commodity and Financial Markets: Insights from GARCH and SVR Models," *International Journal of Financial Studies*, vol. 12, no. 3, Sep. 2024, doi: 10.3390/ijfs12030059.
- [12] P. Oktoviany, R. Knobloch, and R. Korn, "A machine learning-based price state prediction model for agricultural commodities using external factors," *Decisions in Economics and Finance*, vol. 44, no. 2, pp. 1063–1085, Dec. 2021, doi: 10.1007/s10203-021-00354-7.
- [13] K. P. Prabheesh and N. Laila, "Asymmetric effect of crude oil and palm oil prices on Indonesia's output," *Buletin Ekonomi Moneter dan Perbankan/Monetary and banking economics bulletin*, vol. 23, no. 2, pp. 253–268, Aug. 2020, doi: 10.21098/bemp.v23i1.1304.
- [14] R. Tavenard *et al.*, "Tsllearn, A Machine Learning Toolkit for Time Series Data," 2020. [Online]. Available: <https://github.com/tslearn-team/tslearn>.
- [15] D. Chicco, L. Oneto, and E. Tavazzi, "Eleven quick tips for data cleaning and feature engineering," *PLoS Comput Biol*, vol. 18, no. 12, Dec. 2022, doi: 10.1371/journal.pcbi.1010718.
- [16] R. Morrison, X. Liu, and Z. Lin, "Anomaly Detection in Wind Turbine SCADA Data for Power Curve Cleaning," 2021.
- [17] T. Verdonck, B. Baesens, M. Óskarsdóttir, and S. vanden Broucke, "Special issue on feature engineering editorial," *Mach Learn*, vol. 113, no. 7, pp. 3917–3928, Jul. 2024, doi: 10.1007/s10994-021-06042-2.
- [18] V. R. Joseph and A. Vakayil, "SPlit: An Optimal Method for Data Splitting," Mar. 2021, doi: 10.1080/00401706.2021.1921037.
- [19] E. Ergüner Özkoç, "Clustering of Time-Series Data," in *Data Mining - Methods, Applications and Systems*, IntechOpen, 2021. doi: 10.5772/intechopen.84490.
- [20] M. M. Ahsan, M. A. P. Mahmud, P. K. Saha, K. D. Gupta, and Z. Siddique, "Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance," *Technologies (Basel)*, vol. 9, no. 3, Sep. 2021, doi: 10.3390/technologies9030052.
- [21] M. R. Firmansyah and Y. P. Astuti, "Stroke Classification Comparison with KNN through Standardization and Normalization Techniques," *Advance Sustainable Science, Engineering and Technology*, vol. 6, no. 1, Jan. 2024, doi: 10.26877/asset.v6i1.17685.
- [22] A. Bazarova and M. Raseta, "CARRoT: R-package for predictive modelling by means of regression, adjusted for multiple regularisation methods," *PLoS One*, vol. 18, no. 10 October, Oct. 2023, doi: 10.1371/journal.pone.0292597.
- [23] M. Açikkar, "Fast grid search: A grid search-inspired algorithm for optimizing hyperparameters of support vector regression," *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 32, no. 1, pp. 68–92, 2024, doi: 10.55730/1300-0632.4056.
- [24] X. Yang, Z. Zhang, and H. Xu, "RV-FELM: Futures commodity price forecasting based on RIME-VMD algorithm coupled with FA-ELM," *Heliyon*, vol. 10, no. 17, Sep. 2024, doi: 10.1016/j.heliyon.2024.e36631.
- [25] A. L. S. Xavier, B. J. T. Fernandes, and J. F. L. De Oliveira, "A Hybrid Swarm-Based System for Commodity Price Forecasting During the Covid-19 Pandemic," *IEEE Access*, vol. 11, pp. 74379–74387, 2023, doi: 10.1109/ACCESS.2023.3293738.
- [26] J. Wang, Z. Wang, X. Li, and H. Zhou, "Artificial bee colony-based combination approach to forecasting agricultural commodity prices," *Int J Forecast*, vol. 38, no. 1, pp. 21–34, Jan. 2022, doi: 10.1016/j.ijforecast.2019.08.006.
- [27] I. J. Reis Filho, R. M. Marcacini, and S. O. Rezende, "On the enrichment of time series with textual data for forecasting agricultural commodity prices," *MethodsX*, vol. 9, Jan. 2022, doi: 10.1016/j.mex.2022.101758.

- [28] D. Zhang, S. Chen, L. Liwen, and Q. Xia, "Forecasting Agricultural Commodity Prices Using Model Selection Framework with Time Series Features and Forecast Horizons," *IEEE Access*, vol. 8, pp. 28197–28209, 2020, doi: 10.1109/ACCESS.2020.2971591.
- [29] Z. Liu, C. K. Loo, and K. Pasupa, "A novel error-output recurrent two-layer extreme learning machine for multi-step time series prediction," *Sustain Cities Soc*, vol. 66, Mar. 2021, doi: 10.1016/j.scs.2020.102613.
- [30] N. Parida, D. Mishra, K. Das, and N. K. Rout, "Development and performance evaluation of hybrid KELM models for forecasting of agro-commodity price," *Evol Intell*, vol. 14, no. 2, pp. 529–544, Jun. 2021, doi: 10.1007/s12065-019-00295-6.
- [31] W. Cao, X. Liu, and J. Ni, "Parameter Optimization of Support Vector Regression Using Henry Gas Solubility Optimization Algorithm," *IEEE Access*, vol. 8, pp. 88633–88642, 2020, doi: 10.1109/ACCESS.2020.2993267.
- [32] K. K. Paidipati, C. Chesneau, B. M. Nayana, K. R. Kumar, K. Polisetty, and C. Kurangi, "Prediction of Rice Cultivation in India—Support Vector Regression Approach with Various Kernels for Non-Linear Patterns," *AgriEngineering*, vol. 3, no. 2, pp. 182–198, Jun. 2021, doi: 10.3390/agriengineering3020012.
- [33] S. Huang, L. Tian, J. Zhang, X. Chai, H. Wang, and H. Zhang, "Support Vector Regression Based on the Particle Swarm Optimization Algorithm for Tight Oil Recovery Prediction," *ACS Omega*, vol. 6, no. 47, pp. 32142–32150, Nov. 2021, doi: 10.1021/acsomega.1c04923.
- [34] J. H. Cabot and E. G. Ross, "Evaluating prediction model performance," *Surgery (United States)*, vol. 174, no. 3, pp. 723–726, Sep. 2023, doi: 10.1016/j.surg.2023.05.023.
- [35] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," Jul. 19, 2022, *Copernicus GmbH*. doi: 10.5194/gmd-15-5481-2022.
- [36] S. M. Robeson and C. J. Willmott, "Decomposition of the mean absolute error (MAE) into systematic and unsystematic components," *PLoS One*, vol. 18, no. 2 February, Feb. 2023, doi: 10.1371/journal.pone.0279774.
- [37] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput Sci*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.