

Adaptive Particle Swarm Optimization pada Support Vector Regression untuk Peramalan Harga Emas

Adaptive Particle Swarm Optimization in Support Vector Regression for Gold Price Forecasting

Imam Baihaqi^{*1}, Much Aziz Muslim²

Department of Computer Science, Universitas Negeri Semarang

E-mail : imambaihaq@students.unnes.ac.id^{*1}, a212muslim@mail.unnes.ac.id²

^{*}Corresponding author

Received 11 May 2026; Revised 22 June 2026; Accepted 28 June 2026

Abstrak – Peramalan harga emas memainkan peran penting dalam sektor investasi karena harga emas sangat fluktuatif dan dipengaruhi oleh kondisi ekonomi global. *Support Vector Regression* (SVR) merupakan salah satu metode *machine learning* yang terbukti efektif untuk prediksi deret waktu; namun, kinerjanya sangat bergantung pada penentuan parameter optimal seperti C , ϵ , dan γ . Parameter yang tidak akurat dapat menyebabkan model gagal menangkap dinamika pasar atau mengalami *overfitting*. Oleh karena itu, penelitian ini bertujuan untuk meningkatkan kinerja peramalan harga emas dengan mengintegrasikan *Adaptive Particle Swarm Optimization* (APSO) ke dalam model SVR untuk memperoleh kombinasi parameter optimal secara adaptif. Dataset yang digunakan terdiri dari data historis harga emas harian yang diperoleh dari Investing.com mencakup periode Februari 2014 hingga Januari 2024. Evaluasi model dilakukan menggunakan metrik MAE, RMSE, MAPE, MSE, dan R^2 . Hasil eksperimen menunjukkan bahwa model SVR-APSO yang diusulkan mencapai kinerja terbaik dengan nilai MAE sebesar 4.626511, RMSE sebesar 6.355163, MAPE sebesar 0.246459%, MSE sebesar 40.388091, dan nilai R^2 sebesar 0.996617. Temuan ini menunjukkan bahwa optimisasi adaptif terhadap parameter SVR secara signifikan meningkatkan kemampuan model dalam memprediksi fluktuasi harga emas dan memberikan akurasi prediksi yang lebih baik dibandingkan SVR konvensional maupun optimisasi berbasis PSO standar.

Kata Kunci – *Support Vector Regression, Adaptive Particle Swarm Optimization*, Peramalan Harga Emas, *Machine Learning*, Peramalan Deret Waktu

Abstract - Gold price forecasting plays an important role in the investment sector because gold prices are highly volatile and influenced by global economic conditions. Support Vector Regression (SVR) is one of the machine learning methods that has proven effective for time series prediction; however, its performance strongly depends on determining optimal parameters such as C , ϵ , and γ . Inaccurate parameters can cause the model to fail to capture market dynamics or experience overfitting. Therefore, this study aims to improve gold price forecasting performance by integrating Adaptive Particle Swarm Optimization (APSO) with the SVR model to obtain the optimal parameter combination adaptively. The dataset used consists of daily historical gold price data obtained from Investing.com covering the period from February 2014 to January 2024. Model evaluation was conducted using MAE, RMSE, MAPE, MSE, and R^2 metrics. The experimental results show that the proposed SVR-APSO model achieved the best performance with an MAE value of 4.626511, RMSE of 6.355163, MAPE of 0.246459%, MSE of 40.388091, and R^2 value of 0.996617. These findings demonstrate that adaptive optimization of SVR parameters significantly improves the model's ability to predict fluctuations in gold prices and provides better prediction accuracy compared to conventional SVR and standard PSO-based optimization.

Keywords - Support Vector Regression, Adaptive Particle Swarm Optimization, Gold Price Forecasting, Machine Learning, Time Series Forecasting

1. PENDAHULUAN

Emas merupakan komoditas dan aset keuangan yang berkembang pesat di pasar global serta menjadi salah satu aset cadangan yang paling banyak digunakan [1]. Hal ini disebabkan karena emas memiliki keunggulan dibandingkan aset lainnya. Emas dikenal sebagai aset untuk menjaga nilai (*value preservation*), atau disebut juga *safe haven*, karena nilainya cenderung tetap stabil ketika aset lain mengalami penurunan [2]. Selain itu, emas juga berfungsi sebagai sarana diversifikasi portofolio, yang memungkinkan investor mengurangi risiko investasi secara keseluruhan ketika instrumen keuangan lain mengalami kerugian [3]. Penerimaan emas secara universal serta nilai intrinsiknya menjadikan emas sebagai komponen penting baik dalam cadangan nasional maupun strategi investasi pribadi.

Namun demikian, emas juga memiliki kelemahan, yaitu tetap merupakan aset keuangan yang nilainya dapat berfluktuasi secara cepat dan tajam, meskipun korelasi antara emas dan aset lainnya tergolong lemah [4]. Perubahan harga emas yang cepat ini dipengaruhi oleh berbagai faktor seperti tingkat inflasi, perubahan penawaran dan permintaan global, serta ketidakstabilan politik maupun ekonomi di berbagai negara [5]. Dinamika tersebut menyebabkan pergerakan harga emas menjadi sangat volatil dan sulit diprediksi, sehingga menjadi tantangan besar bagi investor dalam menentukan waktu yang optimal untuk membeli atau menjual. Oleh karena itu, diperlukan pendekatan analitis yang lebih maju untuk membantu memprediksi pergerakan harga emas [6]. Salah satu pendekatan tersebut dapat dilakukan melalui penerapan *Machine Learning* yang mampu merepresentasikan data kompleks dengan pola nonlinear pada deret waktu data keuangan.

Bidang kecerdasan buatan dalam *machine learning* bertujuan untuk menciptakan algoritma komputer yang mampu melakukan berbagai tugas seperti klasifikasi, regresi, *clustering*, serta pengenalan pola, yang dapat belajar secara otomatis dari dataset mentah [7]. *Machine learning* telah banyak digunakan untuk peramalan harga komoditas, saham, dan nilai tukar mata uang asing. Hal ini karena *machine learning* mampu memodelkan hubungan nonlinear yang kompleks pada data *time series* sehingga menghasilkan prediksi yang adaptif [8]. Salah satu metode *machine learning* yang sering digunakan dalam peramalan harga komoditas adalah *Support Vector Regression* (SVR).

Dalam bidang prediksi dan peramalan, SVR telah diterapkan pada banyak penelitian. Beberapa penelitian telah mengembangkan model SVR untuk memprediksi harga emas. Puspita et al. [9] menerapkan *Support Vector Regression* (SVR) dan *Grid Search* untuk memperkirakan harga emas batangan Antam. Penelitian tersebut menggunakan data *time series* harian dari 1 Juli 2020 hingga 31 Mei 2023, dengan berbagai rasio data pelatihan dan pengujian seperti 60:40, 70:30, 80:20, dan 90:10. Parameter C , epsilon (ϵ), dan gamma (γ) dioptimasi menggunakan *Grid Search* pada rentang eksponensial. Tiga fungsi kernel (*linear*, *polynomial*, dan *RBF*) dievaluasi, dan hasil penelitian menunjukkan bahwa kernel *linear* memberikan performa terbaik dengan nilai MAPE sebesar 5,43% pada pembagian data 60:40.

Kusumawati et al. [10] menerapkan metode *Support Vector Regression* (SVR) untuk memprediksi harga emas menggunakan lima variabel input harga emas yang mencakup periode Januari 2013 hingga September 2014. Proses penelitian meliputi beberapa tahapan seperti *preprocessing data* (*cleaning*, *reduction*, *normalisasi* menggunakan *Min-Max scaling*, serta pembagian data menjadi 70% data *training* dan 30% data *testing*), seleksi fitur, dan pemodelan menggunakan tiga kernel SVR yaitu *RBF*, *Polynomial*, dan *Linear*. Setiap model dilatih menggunakan 10-fold *cross-validation* dan RMSE digunakan sebagai metode evaluasi. Hasil penelitian menunjukkan bahwa kernel *Linear* memberikan performa prediksi terbaik dengan nilai $C = 35$ dan RMSE sebesar 7,4615.

Gananta et al. [11] melakukan penelitian yang berfokus pada optimasi prediksi harga emas dengan menerapkan *Support Vector Regression* (SVR) dan algoritma *Grid Search* untuk menentukan parameter optimalnya. Data harga emas harian dari Januari 2018 hingga Desember 2021 (1.461 data) digunakan sebagai data pelatihan, sedangkan data Januari 2022 hingga

Desember 2022 (365 data) digunakan sebagai data pengujian. Penelitian ini menggunakan proses CRISP-DM yang memberikan alur kerja terstruktur. Optimasi Grid Search mengeksplorasi 10.000 kemungkinan kombinasi parameter cost (C) dan epsilon (ϵ), dengan metrik Mean Absolute Percentage Error (MAPE) untuk menentukan efektivitas model. SVR yang telah dioptimasi menghasilkan performa yang baik dengan $C = 0,05$ dan $\epsilon = 0,01$, menghasilkan nilai MAPE sebesar 3,73%, yang sedikit lebih baik dibandingkan baseline SVR sebesar 4,35%. Kedua model menunjukkan performa yang sangat baik dalam memprediksi harga emas.

Tantangan fundamental dalam penerapan SVR untuk data keuangan yang volatil seperti emas terletak pada sensitivitas model terhadap pemilihan hiperparameter. Parameter C yang mengontrol *trade-off* antara kesalahan dan kompleksitas, ϵ yang menentukan batas toleransi *error*, serta γ yang mengatur struktur kernel RBF, membentuk ruang pencarian yang sangat luas dan nonlinear. Penentuan parameter secara konvensional seringkali gagal menemukan solusi optimal global karena tidak mampu menyesuaikan strategi pencarian secara dinamis terhadap karakteristik data yang berubah. Ketidakefektifan dalam mengeksplorasi kombinasi parameter ini dapat menyebabkan model kehilangan kemampuan generalisasi pada data yang memiliki volatilitas ekstrem. Oleh karena itu, diperlukan algoritma optimasi yang memiliki kecerdasan adaptif seperti *Adaptive Particle Swarm Optimization* (APSO). APSO memungkinkan penyesuaian *inertia weight* dan *acceleration coefficient* secara otomatis selama iterasi, sehingga proses pencarian parameter SVR menjadi lebih fleksibel dan mampu keluar dari jebakan *local optima*.

Beberapa penelitian telah menerapkan APSO pada berbagai tugas regresi. Rezaei et al. [12], mengusulkan model prediksi cerdas yang menerapkan jaringan saraf berbasis GRU yang ditingkatkan menggunakan algoritma *Adaptive Particle Swarm Optimization* (APSO) untuk memprediksi kecepatan lalu lintas jalan raya pada kondisi curah hujan yang bervariasi. Model APSO-GRU mencapai akurasi prediksi tertinggi, dengan rata-rata sebesar 97,33% pada kondisi hujan tidak kontinu dan 96,74% pada kondisi hujan kontinu, serta mampu mengurangi error lebih dari 2% dibandingkan model GRU dasar. Hao et al. [13] memperkenalkan model hybrid canggih yang mengintegrasikan *Time Attention* (TA), algoritma APSO, dan LSTM untuk meningkatkan prediksi dataset time-series, khususnya harga saham. Hasil penelitian menunjukkan bahwa APSO-TA-LSTM mencapai akurasi tertinggi, dengan nilai RMSE, MAE, MAPE yang lebih rendah, serta nilai R^2 yang lebih tinggi dibandingkan seluruh model pembanding.

Penelitian sebelumnya yang terkait dengan peramalan harga emas menggunakan SVR belum ada yang menerapkan penggunaan APSO, sehingga masih terbuka peluang untuk mengimplementasikan APSO untuk SVR. Penelitian ini mengusulkan model prediksi harga emas dengan mengintegrasikan metode Support Vector Regression (SVR) menggunakan algoritma *Adaptive Particle Swarm Optimization* (APSO) sebagai teknik optimasi parameter C (regularization parameter), ϵ (epsilon-insensitive loss function), dan γ (gamma). Dalam model yang diusulkan, APSO berperan penting dalam menyesuaikan parameter SVR secara dinamis dengan memanfaatkan mekanisme adaptif untuk mengelola fase eksplorasi dan eksploitasi pada *search space*, sehingga menghasilkan kombinasi parameter paling optimal untuk menghasilkan performa model yang lebih unggul. Penelitian ini berkontribusi dalam mengusulkan metode alternatif yang lebih fleksibel dan hasil yang lebih konvergen untuk peramalan harga emas.


2. METODE PENELITIAN

Penelitian ini menggunakan *Support Vector Regression* (SVR) sebagai model dasar (baseline), dengan mengombinasikan *Adaptive Particle Swarm Optimization* (APSO) sebagai metode optimasi parameter SVR. Pengembangan model dan proses pelatihan dilakukan menggunakan bahasa pemrograman Python 3 serta library Scikit-learn, dengan seluruh proses penelitian dijalankan pada platform Kaggle.

Proses prediksi harga emas menggunakan SVR dan APSO diilustrasikan pada Gambar 1. Pertama, data historis harga emas dikumpulkan dalam interval waktu harian. Data historis harga

emas yang digunakan dalam penelitian ini diperoleh dari website Investing.com. Dataset yang digunakan berupa file berformat CSV, di mana setiap baris merepresentasikan harga emas pada interval harian.

Preprocessing data merupakan tahap penting dalam proses pengembangan model dan hasil akhir penelitian. Pada tahap ini, missing values diisi dengan menghitung rata-rata harga sebelumnya. Data duplikat dihapus untuk mencegah redundansi, sedangkan outlier dideteksi menggunakan metode interquartile range (IQR) yang efektif untuk mendeteksi variasi dan nilai ekstrem [14], kemudian diganti dengan rata-rata harga normal sebelumnya. Data kemudian dibagi menjadi data training dan testing dengan proporsi 80:20. Pembagian data tidak dilakukan secara acak, melainkan berdasarkan urutan waktu untuk menghindari adanya kebocoran data (*data leakage*). Model akan mempelajari pola atau hubungan antara nilai fitur dan nilai target menggunakan data training, sedangkan data testing digunakan untuk mengukur performa model.




Gambar 1. Flowchart dari peramalan harga emas menggunakan SVR dan Algoritma APSO

Langkah berikutnya adalah proses feature engineering. Feature engineering merupakan proses merancang, memodifikasi, dan membuat variabel dari data mentah agar menjadi lebih informatif dan relevan sehingga dapat meningkatkan hasil model machine learning [15]. Dengan menggunakan feature engineering, model dapat menginterpretasikan data dengan lebih mudah sehingga dapat meningkatkan performa model [16]. Untuk memastikan bahwa fitur dan target direpresentasikan dalam skala yang seragam, digunakan normalisasi data. Normalisasi ini diterapkan menggunakan metode Min-Max dengan rentang nilai 0–1 [17]. Normalisasi membuat

model dapat belajar secara lebih adil dari setiap fitur sehingga menghasilkan prediksi yang lebih akurat.

Setelah data dibersihkan dan dinormalisasi, proses pelatihan model dilakukan. Penelitian ini menggunakan metode SVR dengan optimasi APSO pada setiap parameter untuk memperoleh kombinasi parameter terbaik. Parameter yang dioptimasi meliputi C , ϵ , dan γ .



Gambar 2. Ilustrasi Visual dari Support Vector Regression [18]

Gambar 2 menyajikan ilustrasi visual dari Support Vector Regression (SVR). Salah satu variasi dari algoritma Support Vector Machine (SVM) adalah pendekatan machine learning yang dikenal sebagai SVR, yang secara khusus dirancang untuk menyelesaikan permasalahan regresi dengan tujuan memprediksi nilai numerik kontinu dibandingkan kelas kategorikal [19]. Konsep utama metode SVR adalah membangun garis atau hyperplane yang dikelilingi oleh sebuah tabung yang dikenal sebagai ϵ -insensitive loss. ϵ -insensitive loss berfungsi sebagai batas toleransi terhadap kesalahan prediksi. Selama nilai prediksi atau support vectors (SVs) berada di dalam wilayah ϵ -insensitive tersebut, maka tidak akan diberikan penalti dan dianggap masih dapat diterima. Namun, apabila nilai berada di luar batas tersebut, maka *slack variables* (ξ_i and ξ_i^*) akan diterapkan untuk mengukur besarnya error relatif terhadap ϵ -insensitive loss. Fungsi objektif dari SVR ditunjukkan pada persamaan berikut [20]:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (1)$$

$$\text{Subject to } \begin{cases} y_i - (\omega^T x_i + b) \leq \epsilon + \xi_i \\ (\omega^T x_i + b) - y_i \geq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (2)$$

Dimana w merepresentasikan weight vector untuk mendefinisikan ruang input, b bertindak sebagai parameter bias, x merepresentasikan nilai input, dan y merupakan output aktual. ϵ menunjukkan margin toleransi error, sedangkan ξ_i, ξ_i^* merupakan slack variables. Karena harga emas memiliki karakteristik nonlinear, maka diterapkan *kernel trick*. Konsep *kernel trick* adalah memetakan data ke dalam feature space berdimensi lebih tinggi. Persamaan berikut digunakan [20]:

$$f(x) = \sum_{i=1}^n (x_i - x_i^*) K(n_i, n_j) + b \quad (3)$$

Dimana $K(n_i, n_j)$ merepresentasikan fungsi kernel yang digunakan, dimana pada kasus ini adalah *Radial Basis Function* (RBF) yang dikarakteristikan oleh parameter gamma (γ), dan $(x_i - x_i^*)$ adalah *Lagrange multiplier*.

Dalam membangun model SVR, sangat penting untuk menentukan nilai setiap parameter guna mencapai performa yang optimal. Parameter utama dalam metode SVR adalah C, ε , dan γ . Parameter C mengontrol seberapa ketat model memberikan penalti terhadap error yang melebihi batas ε -insensitive loss. Dengan kata lain, parameter ini mengatur trade-off antara akurasi model dan kesederhanaan model. Nilai C yang lebih besar akan membuat model meminimalkan error secara lebih agresif, namun dengan konsekuensi menurunnya kemampuan generalisasi model. Parameter ε mendefinisikan batas margin error yang masih dapat diterima, sehingga besarnya parameter ε memengaruhi jumlah support vector yang berada di dalam wilayah ε -insensitive. Sementara itu, parameter γ menentukan bentuk dari kernel *Radial Basis Function* (RBF). Pemilihan nilai γ yang tepat sangat penting untuk memperoleh performa model yang baik. Oleh karena itu, pemilihan kombinasi parameter yang optimal menjadi hal yang sangat penting untuk menghasilkan model SVR dengan performa terbaik.

Adaptive Particle Swarm Optimization (APSO) merupakan pengembangan dari *Particle Swarm Optimization* (PSO) klasik yang dirancang untuk meningkatkan kemampuan pencarian solusi optimal secara adaptif dengan mengubah parameternya secara fleksibel selama proses optimasi [21]. Konsep dasar APSO adalah sekumpulan partikel menempati posisi tertentu dalam ruang pencarian, di mana setiap partikel merepresentasikan kemungkinan solusi dari permasalahan yang diangkat. Setiap partikel mengevaluasi fungsi objektif pada posisinya saat ini, kemudian menentukan arah pergerakan berikutnya berdasarkan posisi saat ini, posisi terbaik partikel tersebut (pBest), dan posisi terbaik dari seluruh partikel (gBest). Partikel kemudian bergerak menuju posisi baru, yang dianggap sebagai satu iterasi selesai. Proses ini diulangi hingga iterasi berakhir. Persamaan umum APSO dapat dinyatakan sebagai berikut [22]:

$$\begin{aligned} v_{id}(t+1) &= \omega v_{id}(t) + c_1 r_1 [p_{id}(t) - x_{id}(t)] + c_2 r_2 [p_{gd}(t) - x_{id}(t)], \\ x_{id}(t+1) &= x_{id}(t) + v_{id}(t+1) \end{aligned} \quad (4)$$

Disini, t merepresentasikan nomor iterasi, x_{id} menunjukkan partikel yang membawa variabel ke-d (yang merepresentasikan setiap parameter SVR), dan v_{id} menunjukkan arah serta kecepatan pergerakan partikel dalam ruang pencarian. ω merupakan inertia weight yang memengaruhi seberapa besar partikel mempertahankan kecepatan sebelumnya, c_1 dan c_2 adalah *individual* dan *social learning factor*, r_1 dan r_2 merepresentasikan bilangan acak pada interval $[0,1]$, p_{id} merupakan posisi terbaik yang pernah dicapai oleh partikel ke-i, dan p_{gd} menunjukkan posisi terbaik yang dicapai oleh seluruh populasi. Nilai ω akan disesuaikan secara adaptif untuk mengatur kecepatan dan posisi setiap partikel. Persamaan yang digunakan adalah sebagai berikut [22]:

$$\omega = \begin{cases} \omega_{min} + \frac{(\omega_{max} - \omega_{min}) * (f - f_{min})}{f_{avg} - f_{min}}, & f \leq f_{avg} \\ \omega_{max}, & f > f_{avg} \end{cases} \quad (5)$$

Selain ω , Nilai dari c_1 dan c_2 juga memengaruhi akurasi hasil optimasi. Nilai c_1 yang terlalu besar menyebabkan partikel terlalu fokus pada pengalaman terbaiknya sendiri, sedangkan nilai c_2 yang terlalu besar membuat partikel terlalu cepat berkonvergensi pada satu titik tertentu. Oleh karena itu, kedua nilai tersebut disesuaikan secara adaptif sepanjang iterasi berlangsung. Persamaan untuk metode ini dapat dinyatakan sebagai berikut [23]:

$$c_1 = c_{1,ini} + \frac{c_{1,fin} - c_{1,ini}}{k_{max}} \cdot k \quad (6)$$

$$(7)$$

$$c_2 = c_{2,ini} + \frac{c_{2,fin} - c_{2,ini}}{k_{max}} \cdot k$$

Dimana $c_{1,ini}$ dan $c_{2,ini}$ merepresentasikan nilai awal dari masing-masing faktor pembelajaran, sedangkan $c_{1,fin}$ dan $c_{2,fin}$ menunjukkan nilai akhirnya. k merepresentasikan jumlah total iterasi yang dilakukan.

Ketika nilai *fitness* seluruh partikel menjadi hampir identik atau cenderung konvergen pada local optimum, maka nilai ω akan ditingkatkan untuk mendorong partikel mengeksplorasi ruang pencarian secara lebih luas. Sebaliknya, ketika nilai *fitness* partikel masih tersebar secara signifikan, ω akan disesuaikan agar partikel lebih fokus dalam mengeksplorasi wilayah ruang pencarian yang menjanjikan. Partikel yang memiliki nilai fungsi objektif lebih baik dibandingkan rata-rata populasi akan diberikan nilai ω yang lebih kecil sehingga dapat tetap berada di sekitar posisi terbaiknya. Sebaliknya, partikel dengan performa di bawah rata-rata akan diberikan nilai ω yang lebih besar agar dapat bergerak lebih aktif dan mengeksplorasi wilayah lain yang mungkin mengandung solusi yang lebih optimal.

Algoritma 1: Pseudo-Code untuk optimalisasi Parameter SVR menggunakan Algoritma APSO

Input:

- Training data
- Parameter bounds for C , ϵ , and γ
- Population size (N)
- Maximum iterations ($MaxIter$)
- Inertia weight limits (ω_{max} , ω_{min})
- Learning factors (c_1 , c_2)

Output:

- Best SVR parameters: (C_{best} , ϵ_{best} , γ_{best})

Begin

Step 1: Initialize particles

- o Randomly generate particle positions $x_i = (C_i, \epsilon_i, \gamma_i)$
- o Randomly initialize velocities v_i
- o Compute fitness $f(x_i)$ using SVR with RMSE as the fitness value
- o Set $pBest_i = x_i$
- o Set $gBest = \text{best } pBest_i$

Step 2: Optimization loop ($t = 1 \rightarrow MaxIter$):

- o Estimate evolutionary state and adapt inertia weight ω , c_1 , c_2
- o Update velocity v_i and position x_i
- o Compute new fitness $f(x_i)$
- o Update $pBest_i$ and $gBest$

Step 3: Return $gBest = (C_{best}, \epsilon_{best}, \gamma_{best})$

End

Algoritma 1 menunjukkan pseudo-code dari algoritma APSO untuk optimasi parameter SVR. Sebelum melakukan inisialisasi partikel pada APSO, langkah pertama adalah menentukan *search space* untuk setiap parameter. *Search space* terdiri dari batas bawah dan batas atas masing-masing parameter, di mana setiap partikel akan bergerak di dalam ruang tersebut. Tabel 1 menunjukkan konfigurasi *search space* yang digunakan.

Tabel 1. Konfigurasi minimum value dan maximum value untuk parameter SVR

SVR Parameter	Nilai Minimum	Nilai Maksimum
C	0.1	10
ϵ	0.01	0.5
γ	0.001	1

Langkah berikutnya adalah inisialisasi partikel dan *velocity*. Pada tahap ini, partikel ditempatkan secara acak di dalam search space, di mana setiap partikel merepresentasikan kombinasi parameter yang unik (C, ϵ , dan γ). *Velocity* partikel juga diinisialisasi secara acak pada tahap awal untuk memastikan bahwa partikel tersebar pada berbagai area ruang solusi. Setelah itu, nilai awal pBest dan gBest dihitung. pBest menyimpan posisi terbaik yang pernah dicapai oleh setiap partikel berdasarkan nilai *fitness*-nya, sedangkan gBest menyimpan posisi terbaik yang ditemukan dari seluruh partikel. Setelah nilai awal ditentukan, nilai *fitness* setiap partikel dihitung menggunakan metrik *Root Mean Square Error* (RMSE) yang diperoleh dari hasil prediksi model SVR pada data training. Tahap selanjutnya adalah menilai fase evolusi algoritma saat ini, apakah berada pada fase eksplorasi (mencari area baru dalam *search space*) atau fase eksploitasi (menyempurnakan solusi di sekitar nilai terbaik). Berdasarkan penilaian tersebut, *inertia weight* dan *learning factor* akan disesuaikan secara adaptif. Penyesuaian ini bertujuan untuk mencegah algoritma terjebak pada solusi lokal sekaligus mempertahankan kemampuannya dalam menemukan solusi global yang optimal.

Selanjutnya, algoritma memperbarui *velocity* dan posisi setiap partikel. Pada tahap ini, setiap partikel memodifikasi *velocity* berdasarkan kombinasi pengalaman terbaiknya sendiri (pBest) dan pengalaman terbaik dari seluruh populasi (gBest). Setelah itu, posisi partikel diperbarui berdasarkan *velocity* baru sehingga memungkinkan partikel bergerak menuju area solusi yang lebih menjanjikan. Proses ini menggambarkan dinamika sosial dan kognitif yang menjadi karakteristik mekanisme APSO. Setelah *velocity* dan posisi diperbarui, nilai *fitness* partikel dihitung kembali. Jika nilai *fitness* partikel pada posisi baru lebih baik dibandingkan pBest sebelumnya, maka pBest akan diperbarui. Jika terdapat partikel dengan nilai *fitness* terbaik dari seluruh partikel, maka partikel tersebut akan menjadi gBest baru. Proses pembaruan ini memastikan bahwa populasi terus belajar menuju solusi yang lebih optimal pada setiap iterasi. Jika jumlah iterasi maksimum belum tercapai, maka proses kembali ke tahap pembaruan posisi partikel. Siklus ini diulangi hingga jumlah iterasi maksimum terpenuhi. Ketika iterasi mencapai batas yang ditentukan, proses diakhiri dengan memilih kombinasi parameter terbaik dari gBest. Nilai parameter optimal tersebut akan diterapkan pada model SVR untuk memperoleh performa prediksi yang paling efektif.

Setelah kombinasi parameter terbaik diperoleh, proses pelatihan akhir model SVR dimulai. Dengan menggunakan parameter optimum global best (gBest), model SVR akhir dijalankan menggunakan data test. Model yang telah dijalankan kemudian dievaluasi untuk menilai seberapa baik model dalam memprediksi hasil. Evaluasi model dilakukan menggunakan beberapa metrik performa. Setiap metrik memiliki persamaan sebagai berikut [24], [25], [26]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

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

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (12)$$

Di mana y_i menunjukkan nilai aktual pada titik data ke- i , $\hat{y}_i$ merupakan nilai prediksi model pada observasi ke- i , dan n menunjukkan jumlah titik data yang digunakan dalam perhitungan tersebut.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dan analisis dari penelitian yang dilakukan. Penelitian menggunakan dataset sekunder yang diperoleh dari Investing.com dengan rentang waktu dari 3 Februari 2014 hingga 26 Januari 2024, yang terdiri dari total 2.557 data harga emas harian. Tabel 2 menunjukkan struktur dataset harga emas. Seperti yang ditunjukkan pada Tabel 2, dataset terdiri dari tujuh kolom yang merepresentasikan berbagai informasi terkait harga emas. Dalam penelitian ini, dataset harga emas yang diperoleh dari Investing.com terdiri dari tujuh kolom sebagaimana ditampilkan secara rinci pada Tabel 2. Data tersebut merepresentasikan pergerakan harga emas harian dalam mata uang USD. Kolom “Price” menunjukkan harga penutupan emas pada setiap hari perdagangan, sedangkan kolom “Open,” “High,” dan “Low” masing-masing merepresentasikan harga pembukaan, harga tertinggi, dan harga terendah yang tercatat pada hari tersebut. Kolom “Volume” dan “Change%” memberikan informasi mengenai aktivitas perdagangan dan persentase perubahan harga dibandingkan dengan harga hari sebelumnya.

Tabel 2. Struktur dan data historis harga emas

Date	Price	Open	High	Low	Volume	Change (%)
02/03/2014	1.259,90	1.242,00	1.266,10	1.240,40	124.750	1,62
02/04/2014	1.251,20	1.257,90	1.260,70	1.246,80	93.150	-0,69
02/05/2014	1.256,90	1.254,20	1.274,50	1.251,80	127.060	0,46
02/06/2014	1.257,20	1.257,70	1.267,50	1.252,50	87.890	0,02
02/07/2014	1.262,90	1.256,90	1.272,00	1.255,50	136.030	0,45
...	...	...	...	...	...	...
...	...	...	...	...	...	...
01/22/2024	2.022,20	2.031,80	2.034,10	2.017,40	152.760	-0,35
01/23/2024	2.025,80	2.023,20	2.039,30	2.020,80	156.700	0,18
01/24/2024	2.016,00	2.030,70	2.037,90	2.011,70	234.460	-0,48
01/25/2024	2.017,80	2.014,80	2.025,60	2.004,00	196.670	0,09
01/26/2024	2.017,30	2.021,00	2.028,10	2.015,60	119.590	-0,02

Dalam penelitian ini, kolom “Price” berfungsi sebagai target harga emas yang akan diprediksi. Secara teknis, pada dataset ini tidak ditemukan missing values maupun outlier. Oleh karena itu, data langsung dibagi menjadi data training dan testing. Sebanyak 2.045 baris data digunakan sebagai data training dan 512 baris data digunakan sebagai data testing. Visualisasi distribusi data dapat dilihat pada Gambar 3.



Gambar 3. Visualisasi distribusi pembagian data untuk training dan testing dalam bentuk *line plot*

Tahap feature engineering dilakukan setelah dataset dibagi. Tahap ini dilakukan dengan memilih kolom *Open*, *High*, *Low*, *Volume*, dan *Change%* sebagai fitur. Setelah tahapan tersebut, data dinormalisasi menggunakan metode *min-max normalization* untuk memastikan seluruh fitur berada pada rentang skala yang seragam. Selanjutnya, data digunakan untuk proses pelatihan model. Nilai parameter pada *Support Vector Regression* (SVR) akan dioptimasi menggunakan algoritma *Adaptive Particle Swarm Optimization* (APSO), yang dilakukan dengan menentukan kombinasi nilai terbaik untuk parameter SVR (C , ϵ , dan γ). Konfigurasi APSO yang diterapkan pada tahap optimasi dapat dilihat pada Tabel 3.

Tabel 3. Konfigurasi Parameter APSO


APSO Parameter	Value
particle	50
iteration	50
inertia weight	0.9
Individual Learning Factor	2.0
Social learning factor	2.0

Konfigurasi APSO pada Tabel 3 didapatkan melalui pengujian empiris dengan mempertimbangkan kemampuan model dalam menghasilkan prediksi yang akurat. Beberapa kombinasi jumlah partikel dan jumlah iterasi diuji, kemudian dipilih konfigurasi dengan 50 partikel dan 50 iterasi, karena mampu menghasilkan proses konvergensi yang stabil serta memberikan nilai error prediksi yang lebih rendah dibandingkan konfigurasi lainnya. Dengan menggunakan konfigurasi tersebut, proses optimasi kemudian dilakukan. Selama proses tersebut, partikel bergerak mengikuti dinamika swarm, di mana *inertia weight* dan *learning factor* disesuaikan secara adaptif. Metode ini meningkatkan kemungkinan partikel menemukan solusi yang lebih baik dengan mencegah proses pelatihan terjebak pada *local optima*. Setelah proses iteratif selesai, diperoleh kombinasi parameter terbaik. Tabel 4 menyajikan hasil optimasi parameter SVR menggunakan APSO.

Tabel 4. Hasil Akhir parameter SVR yang dioptimasi dengan APSO

SVR Parameter	The best value obtained
C	10.00
ϵ	0.004
γ	0.177

Gambar 4 menunjukkan perbandingan antara harga emas aktual dengan harga prediksi model menggunakan model SVR-APSO selama periode awal tahun 2022 hingga awal tahun 2024. Garis hijau yang merepresentasikan hasil prediksi mengikuti dengan sangat dekat garis biru yang menunjukkan harga aktual, menandakan bahwa model berhasil mempelajari pergerakan dinamis serta pola musiman harga emas. Deviasi yang sangat kecil antara kedua kurva menunjukkan bahwa model SVR-APSO memiliki akurasi prediksi yang tinggi dan kemampuan generalisasi yang sangat baik. Hal ini menunjukkan bahwa penyesuaian adaptif *inertia weight* dan *learning factor* pada APSO meningkatkan kemampuan SVR dalam mengoptimasi parameternya secara efisien, sehingga mampu meningkatkan performa prediksi dibandingkan pendekatan optimasi konvensional.



Gambar 4. Grafik perbandingan harga aktual dan harga prediksi dari model SVR-APSO


Penelitian ini juga menyajikan perbandingan performa antara model SVR, SVR-PSO, dan SVR-APSO yang ditunjukkan pada Tabel 5. Model SVR standar menghasilkan performa yang relatif rendah dengan nilai MAE sebesar 45,13, MAPE sebesar 2,30, RMSE sebesar 69,05, dan MSE sebesar 4768,13. Selain itu, nilai R^2 yang diperoleh hanya sebesar 0,6006 yang menunjukkan bahwa kemampuan model dalam menjelaskan variasi data masih terbatas. Nilai error yang cukup besar tersebut menunjukkan bahwa model SVR tanpa optimasi hyperparameter belum mampu menghasilkan prediksi harga emas yang optimal. Setelah dilakukan optimasi menggunakan PSO, performa model meningkat dengan signifikan. Model SVR-PSO berhasil menurunkan nilai MAE menjadi 5,20, MAPE menjadi 0,28, RMSE menjadi 7,04, dan MSE menjadi 49,52, serta meningkatkan nilai R^2 menjadi 0,9959. Selanjutnya, model SVR-APSO menunjukkan performa terbaik dibandingkan model lainnya dengan nilai MAE terendah sebesar 4,63, MAPE sebesar 0,25, RMSE sebesar 6,36, dan MSE sebesar 40,39. Selain itu, nilai R^2 tertinggi sebesar 0,9966 menunjukkan bahwa model memiliki tingkat akurasi prediksi yang sangat baik. Hasil tersebut menunjukkan bahwa pendekatan *Adaptive Particle Swarm Optimization* (APSO) mampu memberikan proses optimasi yang lebih efektif dibandingkan PSO standar sehingga menghasilkan performa prediksi yang lebih unggul.

Tabel 5. Perbandingan diantara performa SVR, SVR-PSO, and SVR-APSO

Model	Metrics				
	MAE	MAPE	RMSE	MSE	R^2
SVR	45.126360	2.295142	69.051671	4768.133254	0.600610
SVR-PSO	5.197261	0.275197	7.036722	49.515456	0.995852
SVR-APSO	4.626511	0.246459	6.355163	40.388091	0.996617

Penelitian ini juga menyajikan scatter plot yang membandingkan distribusi error prediksi antara model SVR, SVR-PSO, dan SVR-APSO, sebagaimana diilustrasikan pada Gambar 5. Pada model SVR standar, titik-titik data terlihat cukup menyebar dan banyak yang berada jauh dari

garis diagonal (*perfect fit*), terutama pada rentang harga tinggi, yang menunjukkan bahwa prediksi model masih memiliki error yang besar dan kurang mampu mengikuti pola data aktual secara akurat. Setelah dilakukan optimasi menggunakan PSO, persebaran titik pada model SVR-PSO menjadi jauh lebih rapat dan mengikuti garis diagonal, menandakan peningkatan akurasi prediksi yang signifikan. Selanjutnya, model SVR-APSO menunjukkan hasil terbaik dengan hampir seluruh titik data berada sangat dekat dengan garis *perfect fit*, yang mengindikasikan bahwa hasil prediksi memiliki tingkat kesesuaian yang sangat tinggi terhadap data aktual. Visualisasi ini memperkuat hasil evaluasi kuantitatif sebelumnya bahwa metode APSO mampu meningkatkan performa SVR dalam memprediksi harga emas secara lebih akurat dibandingkan SVR standar maupun SVR-PSO.



Gambar 5. Perbandingan *scatter plot* dari model (a) SVR, (b) SVR-PSO, dan (c) SVR-APSO

Berdasarkan perbandingan dengan penelitian sebelumnya pada Tabel 6, metode SVR-APSO yang diusulkan menunjukkan performa yang lebih unggul dalam memprediksi harga emas dibandingkan pendekatan sebelumnya. Model SVR yang dioptimasi menggunakan *Adaptive Particle Swarm Optimization* (APSO) berhasil mencapai nilai error yang rendah dengan MAE = 4.626511, MAPE = 0.246459, MSE = 40.388091, dan RMSE = 6.355163, serta nilai koefisien determinasi yang tinggi yaitu $R^2 = 0.996617$, yang menunjukkan akurasi prediksi yang sangat baik. Temuan ini menegaskan bahwa integrasi APSO mampu mengoptimalkan parameter kernel

pada SVR secara efektif, sehingga meningkatkan akurasi prediksi model serta stabilitasnya dalam melakukan peramalan harga emas.

Tabel 6. Perbandingan dari metode yang diusulkan dengan studi sebelumnya

Author (year)	Sumber Data	Model	Performa
Kusumawati et al., 2022	Investing.com	SVR	RMSE: 7.4615
Gananta et al., 2023	Investing.com	SVR-Grid Search	MAPE: 3,73
Proposed Method	Investing.com	SVR-APSO	RMSE: 6.355163 MAPE: 0.246459

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan algoritma *Adaptive Particle Swarm Optimization* (APSO) untuk mengoptimasi parameter pada model *Support Vector Regression* (SVR) dalam prediksi harga emas. Hasil eksperimen menunjukkan bahwa model SVR-APSO yang diusulkan mampu menghasilkan prediksi yang lebih akurat dan stabil dibandingkan SVR konvensional maupun SVR yang dioptimasi menggunakan PSO standar. Mekanisme APSO mampu mengoptimalkan parameter SVR, yaitu C , ε , dan γ , melalui penyesuaian *inertia weight* dan *learning factor* secara adaptif, sehingga proses optimasi dapat menyeimbangkan eksplorasi dan eksploitasi secara lebih efisien serta menghindari *local optima*.

Berdasarkan hasil evaluasi, model SVR-APSO memperoleh performa terbaik dengan nilai MAE sebesar 4.626511, MAPE sebesar 0.246459%, RMSE sebesar 6.355163, MSE sebesar 40.388091, dan R^2 sebesar 0.996617. Selain itu, hasil visualisasi melalui *line plot* dan *scatter plot* menunjukkan bahwa hasil prediksi dari SVR-APSO memiliki tingkat kesesuaian yang sangat tinggi terhadap pergerakan harga emas aktual. Temuan ini menunjukkan bahwa APSO mampu meningkatkan kemampuan prediksi dan generalisasi SVR secara signifikan dalam menangani data time-series keuangan yang bersifat sangat volatil seperti harga emas.

Dengan demikian, penelitian ini menyimpulkan bahwa integrasi APSO dengan SVR merupakan pendekatan yang efektif untuk peramalan harga emas dan dapat menjadi alternatif metode optimasi dalam meningkatkan performa machine learning pada tugas prediksi di bidang keuangan. Untuk penelitian selanjutnya, model yang diusulkan dapat dikembangkan dengan menambahkan variabel eksternal seperti tingkat inflasi, nilai tukar mata uang, indikator geopolitik, maupun data sentimen pasar. Selain itu, penelitian mendatang juga dapat membandingkan metode APSO-SVR dengan pendekatan deep learning seperti LSTM, GRU, maupun model berbasis Transformer untuk mengevaluasi performa prediksi pada dataset keuangan yang lebih kompleks.

DAFTAR PUSTAKA

- [1] J. Chai, C. Zhao, Y. Hu, and Z. G. Zhang, "Structural analysis and forecast of gold price returns," *J. Manag. Sci. Eng.*, vol. 6, no. 2, pp. 135–145, Jun. 2021, doi: 10.1016/j.jmse.2021.02.011.
- [2] Z. P. Cutinha and D. S. S. Mokshagundam, "The Allure of Gold: Exploring the Popularity of Gold as an Investment Choice," *Int. J. Multidiscip. Res.*, vol. 7, no. 1, pp. 1–7, 2025, doi: <https://doi.org/10.36948/ijfmr.2025.v07i01.37758>.
- [3] D. Jayeola and P. O. Olatunji, "Optimizing Portfolio Risk through Diversification: Application of The Black-Litterman Model," *J. Econ. Manag. Trade*, vol. 31, no. 4, pp. 13–19, Apr. 2025, doi: 10.9734/jemt/2025/v31i41280.
- [4] S. Sathyanarayana and T. Mohanasundaram, "The Surge in Gold Price Volatility: Macroeconomic Drivers, Geopolitical Risk, and Market Dynamics," *IRA-Int. J. Manag. Soc. Sci. ISSN 2455-2267*, vol. 21, no. 1, p. 15, Apr. 2025, doi: 10.21013/jmss.v21.n1.p2.

- [5] D. Makala and Z. Li, “Prediction of gold price with ARIMA and SVM,” *J. Phys. Conf. Ser.*, vol. 1767, no. 1, p. 012022, Feb. 2021, doi: 10.1088/1742-6596/1767/1/012022.
- [6] G. Taneva-Angelova, S. Raychev, and G. Ilieva, “A Framework for Gold Price Prediction Combining Classical and Intelligent Methods with Financial, Economic, and Sentiment Data Fusion,” *Int. J. Financ. Stud.*, vol. 13, no. 2, p. 102, Jun. 2025, doi: 10.3390/ijfs13020102.
- [7] P. Carracedo-Reboredo *et al.*, “A review on machine learning approaches and trends in drug discovery,” *Comput. Struct. Biotechnol. J.*, vol. 19, pp. 4538–4558, 2021, doi: 10.1016/j.csbj.2021.08.011.
- [8] R. Sheng, M. Wang, Z. Yao, T. Zhang, and W. Wang, “Comprehensive Machine Learning-Based Time-Series Anomaly Detection for ADN-Based Thruster,” *Adv. Astronaut.*, Oct. 2025, doi: 10.1007/s42423-025-00191-5.
- [9] R. Puspita, H. Cipta, and R. Aprilia, “Application of the Support Vector Regression Method with the Grid Search Algorithm to Predict Movement Gold Price,” *J. Pijar Mipa*, vol. 19, no. 2, pp. 380–385, Mar. 2024, doi: 10.29303/jpm.v19i2.6607.
- [10] Y. Kusumawati, K. Widyatmoko, and C. Irawan, “Gold Price Prediction Using Support Vector Regression,” *J. Appl. Intell. Syst.*, vol. 7, no. 1, pp. 89–102, May 2022, doi: 10.33633/jais.v7i1.6124.
- [11] I. M. Gananta, I. N. Purnama, and K. Fredlina, “OPTIMASI PREDIKSI HARGA EMAS DENGAN METODE SUPPORT VECTOR REGRESSION (SVR) MENGGUNAKAN ALGORITMA GRID SEARCH,” *JATI J. Mhs. Tek. Inform.*, vol. 7, no. 6, pp. 3161–3165, Dec. 2023, doi: <https://doi.org/10.36040/jati.v7i6.8000>.
- [12] M. Rezaei, S. M. H. Hosseini, and B. Nemati, “Presenting an optimal energy management model in microgrids using APSO algorithm,” *Electr. Eng.*, vol. 106, no. 4, pp. 4665–4677, Aug. 2024, doi: 10.1007/s00202-023-02217-3.
- [13] T. Hao, G. Song, and H. Du, “APSO-TA-LSTM: a long and short term memory model combining time attention and adaptive particle swarm optimization for stock forecasting,” *Int. J. Gen. Syst.*, vol. 52, no. 7, pp. 876–893, Oct. 2023, doi: 10.1080/03081079.2023.2222888.
- [14] Ch. S. K. Dash, A. K. Behera, S. Dehuri, and A. Ghosh, “An outliers detection and elimination framework in classification task of data mining,” *Decis. Anal. J.*, vol. 6, p. 100164, Mar. 2023, doi: 10.1016/j.dajour.2023.100164.
- [15] E. Katya, “Exploring Feature Engineering Strategies for Improving Predictive Models in Data Science,” *Res. J. Comput. Syst. Eng.*, vol. 4, no. 2, pp. 201–215, Dec. 2023, doi: 10.52710/rjcs.88.
- [16] 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.
- [17] S. K.N., L. Pinto, S. Gopalan, and P. Balasubramaniam, “Equivalence class and modified Gaussian methods for normalization of time series data on AI models,” *Expert Syst. Appl.*, vol. 277, p. 127166, Jun. 2025, doi: 10.1016/j.eswa.2025.127166.
- [18] F. Zhang and L. J. O’Donnell, “Support vector regression,” in *Machine Learning*, Elsevier, 2020, pp. 123–140. doi: 10.1016/B978-0-12-815739-8.00007-9.
- [19] H. Azis, P. Purnawansyah, N. Nirwana, and F. A. Dwiyanto, “The Support Vector Regression Method Performance Analysis in Predicting National Staple Commodity Prices,” *Ilk. J. Ilm.*, vol. 15, no. 2, pp. 390–397, Aug. 2023, doi: 10.33096/ilkom.v15i2.1686.390-397.
- [20] J. Che, “Support vector regression based on optimal training subset and adaptive particle swarm optimization algorithm,” *Appl. Soft Comput.*, vol. 13, no. 8, pp. 3473–3481, Aug. 2013, doi: 10.1016/j.asoc.2013.04.003.
- [21] G. Kumar, U. P. Singh, and S. Jain, “An adaptive particle swarm optimization-based hybrid long short-term memory model for stock price time series forecasting,” *Soft Comput.*, vol. 26, no. 22, pp. 12115–12135, Nov. 2022, doi: 10.1007/s00500-022-07451-8.
- [22] X. Wu, Z. Yang, and D. Wu, “Advanced Computational Methods for Mitigating Shock and Vibration Hazards in Deep Mines Gas Outburst Prediction Using SVM Optimized by Grey Relational Analysis and APSO Algorithm,” *Shock Vib.*, vol. 2021, no. 1, p. 5551320, Jan. 2021, doi: 10.1155/2021/5551320.
- [23] N. Wang, J. Zhang, Y. Xiang, and S. Huang, “A high-precision displacement prediction model for landslide geological hazards based on APSO-SVR-LSTM combination,” *Front. Earth Sci.*, vol. 13, p. 1597570, Jun. 2025, doi: 10.3389/feart.2025.1597570.

- [24] X. Fu *et al.*, “Water quality prediction of copper-molybdenum mining-beneficiation wastewater based on the PSO-SVR model,” *Front. Environ. Sci. Eng.*, vol. 17, no. 8, p. 98, Aug. 2023, doi: 10.1007/s11783-023-1698-9.
- [25] A. Vidal and W. Kristjanpoller, “Gold volatility prediction using a CNN-LSTM approach,” *Expert Syst. Appl.*, vol. 157, p. 113481, Nov. 2020, doi: 10.1016/j.eswa.2020.113481.
- [26] L. Chen, Y. Pan, and D. Zhang, “Prediction of Carbon Emissions Level in China’s Logistics Industry Based on the PSO-SVR Model,” *Mathematics*, vol. 12, no. 13, p. 1980, Jun. 2024, doi: 10.3390/math12131980.