

Prediksi Harga Bitcoin Menggunakan *Support Vector Regression (SVR)* Berbasis *Particle Swarm Optimization (PSO)*

Rizky Parluka¹, Wahyudi², Ahmad Budi Trisnawan³, Akhlis Munazilin⁴, Prasasti Karunia Farista Ananto⁵

¹Teknologi Informasi, Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur

²Informatika, Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur

³Sistem Informasi, Sains, Teknologi, Teknik, dan Matematika, Universitas Mahakarya Asia

⁴Ilmu Komputer, Sains dan Teknologi, Universitas Ibrahimy

⁵Sistem Informasi, Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur

¹rizkyparlika.if@upnjatim.ac.id, ²21081010100@student.upnjatim.ac.id, ³abudit75@gmail.com,

⁴akhlismunazilin@gmail.com, ⁵prasasti.karunia.fasilkom@upnjatim.ac.id

Abstract

Bitcoin prices exhibit high volatility and complex non-linear patterns, making accurate price predictions challenging in the context of cryptocurrency market research. In this study, an optimized SVR-PSO predictive modeling approach is developed to help predict Bitcoin prices, and its performance is compared against a Grid Search-optimized SVR baseline. The SVR-PSO modeling approach developed in this study uses daily historical Bitcoin records obtained from Yahoo Finance between March 10, 2019, and May 11, 2026. The data consists of open, high, low, close, and volume values as attributes, and the closed value as the target. Data preprocessing consists of chronologically organizing the data, removing blank rows, min-max scaling, and splitting the data into 80:20 for training and testing. PSO is used to identify the optimal SVR parameters C , ϵ , and γ with the aim of reducing MAPE. The optimal parameters for the SVR model are $C = 501$, $\epsilon = 0.001$, and $\gamma = 0.001$. On the test dataset, the SVR-PSO model achieved an MAE of 1,521.47, an RMSE of 2,101.70, a MAPE of 1.65%, and an R^2 of 0.9813, outperforming the SVR-GridSearch baseline (MAE 1,559.87; RMSE 2,128.52; MAPE 1.69%; R^2 0.9809). These results suggest that SVR-based Bitcoin price prediction is more accurate when optimized using PSO than using a discrete Grid Search.

Keywords: bitcoin, support vector regression, particle swarm optimization, machine learning, prediction

Abstrak

Harga Bitcoin menunjukkan volatilitas tinggi dan pola non-linear yang kompleks, sehingga cukup sulit untuk memprediksi harga secara akurat dalam konteks riset pasar *cryptocurrency*. Dalam studi ini, dikembangkan pendekatan pemodelan prediktif SVR yang dioptimalkan menggunakan PSO untuk memprediksi harga Bitcoin, yang kinerjanya kemudian dibandingkan dengan model SVR *baseline* yang dioptimalkan menggunakan *Grid Search*. Pendekatan pemodelan SVR-PSO yang dikembangkan dalam studi ini menggunakan catatan historis harian Bitcoin yang diperoleh dari *Yahoo Finance* antara 10 Maret 2019 dan 11 Mei 2026. Data tersebut terdiri dari nilai *open*, *high*, *low*, *close*, dan *volume* sebagai atribut, dan nilai *closed* sebagai target. Pra-pemrosesan data terdiri dari pengaturan data secara kronologis, penghapusan baris kosong, penskalaan min-max, dan pembagian data menjadi 80:20 untuk pelatihan dan pengujian. PSO digunakan untuk mengidentifikasi parameter SVR optimal C , ϵ , dan γ dengan tujuan mengurangi MAPE. Parameter optimal untuk model SVR adalah $C = 501$, $\epsilon = 0.001$, dan $\gamma = 0.001$. Pada dataset pengujian, model SVR-PSO menghasilkan MAE sebesar 1.521,47, RMSE sebesar 2.101,70, MAPE sebesar 1,65%, dan R^2 sebesar 0,9813, mengungguli model *baseline* SVR-GridSearch (MAE 1.559,87; RMSE 2.128,52; MAPE 1,69%; R^2 0,9809). Hasil ini menunjukkan bahwa prediksi harga Bitcoin berbasis SVR lebih akurat ketika dioptimalkan menggunakan PSO dibandingkan menggunakan *Grid Search* yang bersifat diskret.

Kata kunci: bitcoin, support vector regression, particle swarm optimization, machine learning, prediksi

©This work is licensed under a Creative Commons Attribution -ShareAlike 4.0 International License

1. Pendahuluan

Keputusan investasi yang berkaitan dengan aset mata uang kripto memerlukan analisis pergerakan harga yang akurat karena sifat volatilitasnya [1]. Inilah sebabnya mengapa menggunakan metode berbasis komputasi untuk memprediksi dan meramalkan volatilitas mata uang kripto [2]. Harga Bitcoin berfluktuasi sangat luas sehingga sering dipilih sebagai contoh aset digital dalam model peramalan [3]. Penelitian sebelumnya telah menunjukkan bahwa penggunaan algoritma pembelajaran mesin untuk memprediksi volatilitas Bitcoin memberikan hasil yang andal dibandingkan dengan metode tradisional [4]. Hal

ini disebabkan oleh sifat harga Bitcoin yang volatil dan kompleks dibandingkan dengan pasar keuangan tradisional [5].

Oleh karena itu, pola harga Bitcoin kompleks karena interaksi berbagai faktor, termasuk penawaran dan permintaan, sentimen pasar, rezim regulasi, dan kemajuan teknologi dalam ekosistem *blockchain* [6,7]. Sentimen pasar global mencakup persepsi investor tentang tingkat harga saat ini dan masa depan serta ekspektasi mereka tentang bagaimana faktor-faktor seperti berita, regulasi, atau kemajuan teknologi *blockchain* akan memengaruhi harga tersebut dalam jangka pendek atau panjang. Tekanan regulasi akan

mempercepat atau memperlambat penerimaan aset digital dalam pasar tertentu [8]. Hal ini biasanya menghasilkan tingkat ketidakpastian yang biasanya menghasilkan pola nonlinier yang sangat berbeda dari pola yang biasa dihasilkan oleh aset keuangan tradisional. Situasi ini membutuhkan kerangka analitis yang memiliki kemampuan untuk mengidentifikasi pola tersembunyi dalam data historis pasar sehingga keputusan yang dibuat di masa mendatang akan berbasis data dan memiliki probabilitas tinggi untuk mencapai hasil yang diinginkan [9].

Telah dilakukan sejumlah besar penelitian yang menunjukkan bahwa teknik pembelajaran mesin mampu memodelkan sifat rumit harga bitcoin, yang biasanya hadir secara kompleks dan nonlinier. Misalnya, studi yang dilakukan dengan membandingkan berbagai algoritma pembelajaran mesin pada harga historis bitcoin menemukan bahwa algoritma pembelajaran mesin memiliki kinerja prediksi yang lebih baik dibandingkan dengan metode statistik standar seperti yang dijelaskan dalam [9]. Analisis volatilitas bitcoin menunjukkan bahwa pola harga sangat fluktuatif sehingga tidak mendukung asumsi linier dari model prediksi harga tradisional tertentu yang lebih lanjut menyoroti bahwa model pembelajaran mesin sangat cocok untuk menganalisis kompleksitas pola ini tanpa adanya linearitas tersebut [10]. Oleh karena itu, terdapat banyak sekali algoritma pembelajaran mesin dalam literatur yang telah digunakan untuk menganalisis hubungan ini di berbagai variabel harga secara lebih efektif dan efisien daripada model klasik yang telah digunakan secara historis; beberapa di antaranya termasuk *Random Forest* (RF), *Long Short Term Memory* (LSTM), dan *Support Vector Regression* (SVR) [11,12].

Support Vector Regression (SVR) adalah salah satu algoritma pembelajaran mesin yang paling populer untuk pemodelan data non-linier [13]. *Support Vector Regression* (SVR) memiliki kemampuan untuk memodelkan hubungan nonlinier yang kompleks melalui penggunaan fungsi *kernel*, seperti *Radial Basis Function* (RBF), sehingga model dapat mempelajari pola data yang tidak dapat direpresentasikan secara linier [14]. Manfaat utama menggunakan SVR adalah memungkinkan untuk mengontrol kompleksitas model melalui beberapa parameter kunci (*Cost* (C), *gamma* (γ) dan *Epsilon* (ϵ)). Parameter *Cost* C menentukan jumlah kesalahan yang diizinkan oleh model kita untuk menyesuaikan data pelatihan. Parameter *Gamma* γ menentukan seberapa besar jarak antara dua titik dalam data kita memengaruhi fungsi kernel, sedangkan parameter *Epsilon* ϵ mendefinisikan rentang di sekitar fungsi regresi di mana kesalahan tidak dihitung sebagai penyimpangan nyata. Pengaturan parameter yang tepat secara bersamaan memungkinkan *Support Vector Regression* (SVR) untuk membangun model yang dapat dipetakan ke ruang fitur berdimensi lebih tinggi dengan akurasi tinggi dan untuk membangun model

yang dapat merepresentasikan pola data nonlinier secara optimal [15].

Namun, efektivitas SVR dapat sangat dipengaruhi oleh seberapa baik tiga *hyperparameter* utamanya diatur, yaitu nilai C, γ , dan ϵ . Ketiga parameter tersebut memiliki dampak langsung pada kemampuan model SVR untuk melakukan generalisasi dan mempelajari pola non-linear dari data [16]. Memilih nilai yang salah untuk parameter ini akan menghasilkan model yang terlalu "kaku" (*underfitting*) atau terlalu "sensitif" terhadap noise dalam data (*overfitting*) dan dengan demikian menghasilkan prediksi yang tidak dapat dicapai [17]. Dengan adanya volatilitas tinggi dalam data *cryptocurrency*, optimasi parameter tidak dapat diabaikan karena parameter optimal akan membantu meningkatkan kinerja keseluruhan model untuk menangkap dan menggunakan pola historis yang relevan untuk prediksi tren masa depan yang lebih akurat [15].


Optimasi parameter secara tradisional dilakukan menggunakan teknik pencarian manual atau pencarian grid. Teknik-teknik ini memerlukan evaluasi semua kemungkinan kombinasi parameter. Hal ini mengakibatkan area pencarian yang luas serta waktu yang lama untuk menghitung kombinasi parameter tersebut seiring bertambahnya jumlah kombinasi. Pencarian grid juga telah terbukti berkinerja lebih buruk daripada teknik pencarian lainnya karena seluruh grid tidak selalu menghasilkan solusi optimal ketika melakukan pencarian di area pencarian yang luas [18]. Algoritma PSO, sebuah algoritma metaheuristik, menyediakan cara yang efisien untuk melakukan pencarian ruang solusi secara iteratif dan adaptif. Premis dasar algoritma PSO didasarkan pada "kecerdasan kelompok", di mana "partikel pencarian" akan terbang melalui ruang solusi dengan mengikuti pengalaman mereka sendiri (*personal best*) dan pengalaman terbaik secara keseluruhan (*global best*) sehingga mencapai keseimbangan antara pencarian dan hasil pencarian (pengalaman). [19]. Pendekatan ini secara efektif dapat mengidentifikasi kombinasi parameter SVR yang paling sesuai tanpa terjebak pada optimum lokal, serta mengurangi beban komputasi dibandingkan pencarian manual. Pendekatan ini memungkinkan identifikasi kombinasi parameter SVR yang optimal secara lebih efisien, mengurangi risiko terjebak pada solusi lokal, dan berbagai studi lokal menunjukkan bahwa integrasi SVR dengan optimasi PSO dapat meningkatkan akurasi prediksi harga Bitcoin serta aset *cryptocurrency* lainnya secara signifikan.

Dalam konteks ini, tujuan penelitian ini adalah untuk menghasilkan model, berdasarkan SVR yang dioptimalkan dengan PSO, yang akan memprediksi harga Bitcoin. Integrasi optimasi PSO dalam SVR diharapkan dapat memberikan prediksi harga Bitcoin yang lebih akurat; hal ini akan membuat model lebih kuat dalam hal pola data yang volatil dan menciptakan *platform* komputasi cerdas yang kuat untuk pemodelan

aset kripto. Dari perspektif akademis, penelitian ini akan menambah metode berbasis pembelajaran mesin yang dioptimalkan secara cerdas untuk menganalisis deret waktu keuangan, khususnya dalam mengatasi kesulitan volatilitas dan non-linearitas yang dialami di pasar mata uang kripto. Dalam praktiknya, temuan penelitian ini akan berfungsi sebagai panduan bagi investor dan analis pasar dalam mempersiapkan strategi investasi dan membuat keputusan berbasis data yang lebih fleksibel terhadap sifat pasar yang selalu berubah.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan *machine learning* berbasis *Support Vector Regression* (SVR) yang dioptimasi menggunakan *Particle Swarm Optimization* (PSO) untuk memprediksi harga Bitcoin berdasarkan data historis deret waktu. Alur dari penelitian ini dapat dilihat pada gambar 1.



Gambar 1. Alur Penelitian

Tahapan penelitian seperti yang dapat dilihat pada Gambar 1 meliputi pengumpulan data, prapemrosesan data, optimasi parameter model menggunakan PSO, pelatihan model, serta evaluasi performa prediksi menggunakan beberapa metrik evaluasi.

2.1. Pengumpulan Data

Penelitian ini menggunakan dataset historis harga Bitcoin dalam bentuk data deret waktu harian (*daily time series*). Data yang digunakan dalam penelitian ini merupakan data historis harga Bitcoin harian yang diperoleh dari platform *Yahoo Finance* [20]. Dataset diakses menggunakan *library yfinance* pada bahasa pemrograman *Python* dengan simbol aset BTC-USD. Data yang digunakan mencakup periode 10 Maret 2019 hingga 11 Mei 2026 dan terdiri dari beberapa atribut, yaitu *Open*, *High*, *Low*, *Close*, dan *Volume*. Variabel target prediksi berupa harga penutupan hari berikutnya (*close next day*) dibentuk melalui proses pergeseran (*shifting*) data pada atribut *close* ke satu periode waktu berikutnya.

Setelah menghasilkan target, data diurutkan berdasarkan stempel waktu untuk menjaga konsistensi data deret waktu. Proses pembersihan dilakukan dengan menghapus baris yang berisi nilai kosong akibat pergeseran target (pergeseran target prediksi). Dataset diproses menggunakan *Python* dan disimpan sebagai file nilai yang dipisahkan koma (CSV).

Penelitian ini menggunakan karakteristik harga pembukaan, tertinggi, terendah, penutupan, dan volume sebagai variabel masukan untuk model, dengan perubahan atribut penutupan digunakan sebagai variabel keluaran atau target untuk memprediksi harga penutupan bitcoin untuk hari berikutnya. Penggunaan beberapa atribut harga dan volume perdagangan yang berbeda dimaksudkan untuk membantu model dalam mengenali tren historis dalam perilaku harga bitcoin.

2.2. Prapemrosesan Data

Dataset dipersiapkan untuk digunakan dalam pelatihan dan pengujian model melalui tahap praproses data. Tujuan dari proses ini adalah untuk menyediakan data berkualitas lebih tinggi dan data deret waktu yang konsisten agar model dapat mempelajari pola harga Bitcoin historis secara optimal [21]. Berbagai tahap praproses data yang diselesaikan dalam penelitian ini meliputi: pembersihan data, partisi data, normalisasi data, dan pembuatan set validasi untuk digunakan dalam mengoptimalkan parameter [15].

a. Pembersihan dan Pengurutan Data

Dataset Bitcoin historis tertua hingga terbaru yang digunakan diatur dalam urutan kronologis berdasarkan stempel waktu. Data diperiksa untuk memastikan urutannya sesuai dengan stempel waktu, dan setelah penentuan urutan, data diurutkan ulang berdasarkan stempel waktu untuk memastikan bahwa data deret waktu memiliki urutan data deret waktu yang konsisten sebelum digunakan untuk pelatihan model. Hubungan antara data deret waktu selama proses pelatihan harus dipertahankan dengan memiliki urutan waktu yang benar untuk data deret waktu selama metode pelatihan [22]. Untuk membuat nilai target untuk prediksi, proses tersebut melibatkan pergeseran atribut penutup. Hal ini menyebabkan entri kosong di beberapa baris di akhir dataset. Agar data dapat digunakan dalam pelatihan model, baris dengan nilai kosong dihapus selama proses pembersihan data.

b. Pembagian Data

Setelah pembersihan data selesai, data kemudian dibagi menjadi set pelatihan dan set pengujian menggunakan rasio 80:20. Distribusi data akan dilakukan secara berurutan, tanpa pengacakan, agar tidak merusak karakteristik temporal dari deret waktu [23]. Dataset pelatihan dan dataset pengujian digunakan dalam proses pelatihan dan pengujian model; dataset pengujian akan digunakan untuk mengevaluasi kinerja model pada dataset yang belum pernah dilihat sebelumnya.

c. Normalisasi Data

Dataset fitur dan target dinormalisasi menggunakan MinMax Scaling sebagai prosedur. Tujuan normalisasi ini adalah untuk membuat fitur dataset lebih homogen, yang membantu membuat proses pelatihan model *Support Vector Regression* (SVR) lebih stabil. Proses normalisasi dilakukan menggunakan *MinMaxScaler* dari interval nilai $[0,1]$. Proses normalisasi membantu menstabilkan proses pelatihan dan meminimalkan distorsi skala antar fitur [24]. Parameter normalisasi yang diperoleh dari dataset pelatihan kemudian diterapkan pada dataset pengujian untuk menghilangkan kemungkinan kebocoran data selama periode pelatihan model.

2.3. Support Vector Regression (SVR)

Support Vector Regression (SVR) merupakan salah satu metode *machine learning* yang digunakan untuk menyelesaikan permasalahan regresi dengan membangun fungsi prediksi berdasarkan hubungan antara variabel masukan dan variabel target [25]. SVR bekerja dengan membentuk fungsi regresi yang mampu memprediksi nilai target berdasarkan pola hubungan antar data masukan [26]. Selain itu, fungsi kernel RBF umumnya diadopsi dalam memprediksi data keuangan dan data deret waktu karena fleksibilitasnya dalam merepresentasikan pola data yang kompleks.

Secara umum, fungsi prediksi (regresi) yang dibentuk oleh SVR dapat dituliskan sebagai Persamaan (1).

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

dengan $f(x)$ adalah nilai hasil prediksi model SVR; n adalah jumlah data pelatihan; α_i dan α_i^* adalah koefisien Lagrange (multiplier) hasil optimasi yang menentukan besarnya kontribusi setiap data pelatihan ke- i terhadap fungsi prediksi; x_i adalah data pelatihan (*support vector*) dan x adalah data yang akan diprediksi; sedangkan b adalah nilai bias (intercept) dari fungsi regresi. Semakin besar selisih $\alpha_i - \alpha_i^*$ pada suatu titik data, semakin besar pula pengaruh titik tersebut terhadap hasil prediksi model.

dengan $K(x)$ merupakan fungsi *kernel*. Dalam penelitian ini digunakan fungsi kernel *Radial Basis Function* (RBF) yang dituliskan pada Persamaan (2).

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

dengan x_i dan x_j adalah dua titik data yang dibandingkan, sedangkan $\|x_i - x_j\|^2$ adalah kuadrat jarak Euclidean di antara keduanya. Parameter *gamma* (γ) mengatur seberapa cepat nilai kemiripan (kernel) ini menurun seiring bertambahnya jarak: nilai γ yang besar membuat pengaruh suatu titik data bersifat sangat lokal, sedangkan nilai γ yang kecil membuat pengaruhnya menyebar lebih luas.

Dalam penelitian ini, model SVR dikembangkan menggunakan tiga kriteria utama: C , *epsilon* (ϵ), dan

gamma (γ). Kriteria C digunakan untuk menentukan ambang batas kesalahan antara data pelatihan model dan akurasi model. Nilai *epsilon* (ϵ) menentukan varians maksimum yang diizinkan selama perhitungan regresi. Nilai *gamma* (γ) menentukan kontribusi setiap titik pelatihan dalam menciptakan model regresi yang terkait dengan fungsi kernel RBF.

Pemilihan parameter yang karenanya memengaruhi kemampuan prediksi model. Oleh karena itu, *Particle Swarm Optimization* (PSO) digunakan untuk mengoptimalkan parameter SVR sehingga kombinasi parameter untuk model SVR dapat diperoleh yang akan menghasilkan kinerja prediksi yang lebih baik.

2.4. Particle Swarm Optimization (PSO)

Particle Swarm Optimization (PSO) adalah algoritma yang dikembangkan berdasarkan inspirasi dari sekelompok makhluk hidup seperti burung atau ikan, misalnya, burung atau ikan dapat mencari posisi terbaik untuk hidup mereka sendiri. Setiap partikel PSO mewakili solusi statistik yang memiliki nilai fitness spesifik untuk mencari solusi optimal dalam ruang pencarian masalah.[19].

Dalam kerangka penelitian ini, parameter dalam kerangka SVR dioptimalkan dengan bantuan PSO. C , ϵ , dan γ mewakili tiga parameter dalam SVR yang dioptimalkan menggunakan PSO [27]. Nilai parameter SVR untuk satu partikel PSO mewakili kombinasi nilai parameter SVR yang akan dimasukkan ke dalam model SVR untuk menjalankan model SVR pada dataset pelatihan dan validasi internal untuk mendapatkan hasilnya.

Optimasi dilakukan secara iteratif dan memperbarui kecepatan dan posisi partikel individu dalam *swarm*. Pembaruan kecepatan dan posisi partikel bergantung pada *personal best*/pbest, dari partikel serta *global best*/gbest, dari seluruh populasi partikel (*swarm*) [28]. Persamaan untuk memperbarui kecepatan dan posisi partikel dalam algoritma PSO adalah Persamaan (3) dan Persamaan (4).

$$v_i^{(t+1)} = wv_i^t + c_1r_1(pbest_i - x_i^t) + c_2r_2(gbest - x_i^t) \quad (3)$$

$$x_i^{(t+1)} = x_i^t + v_i^{(t+1)} \quad (4)$$

dengan v_i^t dan x_i^t berturut-turut adalah kecepatan dan posisi partikel ke- i pada iterasi ke- t , dengan posisi partikel merepresentasikan satu kombinasi nilai parameter SVR (C , ϵ , γ); w adalah bobot inersia yang mengendalikan kecenderungan partikel mempertahankan arah gerakannya sebelumnya; c_1 (koefisien kognitif) dan c_2 (koefisien sosial) adalah bobot yang mengatur seberapa besar pengaruh pengalaman individu dan pengalaman kelompok terhadap pergerakan partikel; r_1 dan r_2 adalah bilangan acak pada rentang $[0,1]$ yang memberikan variasi pada proses pencarian; sedangkan $pbest_i$ adalah posisi

terbaik yang pernah dicapai partikel ke- i dan g_{best} adalah posisi terbaik yang pernah dicapai oleh seluruh partikel dalam *swarm*. Persamaan (4) kemudian menghitung posisi partikel pada iterasi berikutnya dengan menambahkan kecepatan baru hasil Persamaan (3) ke posisi sebelumnya.

Nilai Mean Absolute Percentage Error (MAPE) merupakan Fungsi Objektif dalam penelitian ini. Nilai MAPE digunakan sebagai ukuran kesalahan prediksi model SVR dalam proses optimasi parameter. Semakin besar nilai MAPE, semakin besar pula ukuran kesalahan prediksinya, dan sebaliknya.

Dalam proses PSO, terdapat beberapa parameter yang perlu dioptimalkan, antara lain; jumlah partikel, jumlah iterasi, bobot inersia (w), koefisien kognitif ($c1$), dan koefisien sosial ($c2$). Proses PSO menghasilkan nilai parameter optimal, yang akan digunakan untuk mengembangkan model SVR guna memperkirakan harga bitcoin.

2.5. Pelatihan dan Evaluasi Model

Setelah proses *Particle Swarm Optimization* (PSO) selesai mengoptimalkan parameter, kumpulan parameter terbaik digunakan untuk membuat model *Support Vector Regression* (SVR) akhir, menggunakan semua data pelatihan yang dinormalisasi untuk melatih model SVR. Setelah pelatihan selesai, model SVR kemudian digunakan untuk memprediksi harga Bitcoin pada data pengujian, yaitu data yang tidak digunakan untuk melatih atau mengoptimalkan parameter model apa pun.

Prediksi yang dibuat oleh model, yang telah dinormalisasi, juga nilainya dikembalikan ke skala yang sama dengan data sebenarnya menggunakan transformasi invers. Dengan demikian, hal ini memungkinkan prediksi untuk dibandingkan secara langsung dengan nilai harga Bitcoin aktual yang ada dalam data uji.

Beberapa matriks evaluasi diterapkan untuk menentukan seberapa baik model bekerja: MAE (mean absolute error), RMSE (root mean squared error), MAPE (mean absolute percentage error), dan R^2 (koefisien determinasi) [29]. MAE adalah jumlah kesalahan antara nilai aktual dan nilai prediksi. RMSE menghitung kesalahan keseluruhan yang disebabkan oleh prediksi model berdasarkan perbedaan antara nilai aktual dan nilai prediksi. MAPE menunjukkan persentase nilai aktual yang diwakili oleh prediksi model terhadap nilai tersebut. R^2 (koefisien determinasi) adalah ukuran seberapa baik model dapat mewakili hubungan antara nilai prediksi dan nilai aktual [30]. Representasi matematis dari matriks evaluasi ini ditunjukkan pada (Persamaan 5-8).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

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

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

dengan n adalah jumlah data pada himpunan uji; y_i adalah nilai aktual (harga Bitcoin sebenarnya) untuk data ke- i ; $\hat{y}_i$ adalah nilai hasil prediksi model untuk data ke- i ; dan $\bar{y}$ adalah rata-rata nilai aktual pada data uji. Pada Persamaan (5), selisih $y_i - \hat{y}_i$ dimutlakkan (MAE) sehingga error positif dan negatif tidak saling meniadakan, sedangkan pada Persamaan (6) selisih tersebut dikuadratkan terlebih dahulu (RMSE) sehingga kesalahan yang besar diberi bobot lebih berat. Persamaan (7) menyatakan *error* dalam bentuk persentase relatif terhadap nilai aktual (MAPE), dan Persamaan (8) mengukur proporsi variasi data aktual yang mampu dijelaskan oleh model (R^2); nilai R^2 yang mendekati 1 menunjukkan model mampu merepresentasikan pola data dengan sangat baik.

Bersamaan dengan penggunaan metrik evaluasi numerik, prediksi model juga akan divisualisasikan dengan grafik yang menampilkan nilai aktual dan nilai prediksi untuk tujuan perbandingan. Grafik ini digunakan untuk menentukan seberapa baik model mengikuti tren harga/pergerakan harga Bitcoin dalam data yang digunakan sebagai data uji.

3. Hasil dan Pembahasan

Bab ini menyajikan hasil implementasi dan evaluasi model prediksi harga Bitcoin menggunakan metode *Support Vector Regression* (SVR) yang dioptimasi dengan *Particle Swarm Optimization* (PSO) sebagai model utama penelitian. Proses eksperimen dilakukan secara bertahap mulai dari analisis dataset, prapemrosesan data, optimasi parameter SVR menggunakan *Grid Search* sebagai model *baseline*, optimasi parameter SVR menggunakan PSO sebagai model utama, hingga evaluasi dan perbandingan performa kedua model pada data pengujian. *Grid Search* dipilih sebagai *baseline* karena merepresentasikan teknik optimasi *hyperparameter* konvensional yang mengevaluasi kombinasi parameter secara ekshaustif pada ruang pencarian diskret, sehingga hasilnya dapat digunakan sebagai acuan untuk mengukur seberapa besar peningkatan performa yang diberikan oleh pendekatan optimasi kontinu berbasis PSO.

3.1. Deskripsi Dataset

Dataset yang digunakan dalam eksperimen disimpan dalam berkas *btc_sinta.csv* dan diperoleh dari *Yahoo Finance* dengan simbol aset *BTC-USD*. Data mencakup periode 10 Maret 2019 hingga 11 Mei 2026, terdiri dari 2.620 observasi harian, dan memuat kolom *timestamp*, *open*, *high*, *low*, *close*, *close_next_day*, dan *volume*. Kolom *timestamp* berfungsi sebagai penanda urutan waktu, sedangkan kolom harga dan volume digunakan sebagai variabel numerik untuk pemodelan.

Secara implementatif, dataset disiapkan sebagai data deret waktu harian dengan target prediksi berupa *close_next_day*, sehingga setiap baris data merepresentasikan kondisi pasar pada satu hari tertentu dan nilai target pada hari berikutnya. Untuk memberikan gambaran yang jelas mengenai struktur dataset, Tabel 1 menampilkan kolom-kolom beserta penjelasan singkat masing-masing.

Tabel 1. Struktur Dataset

Atribut	Deskripsi
<i>timestamp</i>	Penanda waktu observasi harian
<i>open</i>	Harga pembukaan Bitcoin
<i>high</i>	Harga tertinggi Bitcoin
<i>low</i>	Harga terendah Bitcoin
<i>close</i>	Harga penutupan Bitcoin
<i>close_next_day</i>	Harga penutupan hari berikutnya sebagai target
<i>volume</i>	Volume perdagangan Bitcoin

Setelah meninjau Tabel 1, terlihat bahwa dataset mencakup informasi harga harian yang lengkap dan volume perdagangan, yang menjadi fitur input utama dalam model SVR dan SVR-PSO. Struktur ini memastikan bahwa model dapat memanfaatkan seluruh atribut relevan untuk mempelajari pola historis pergerakan harga Bitcoin dan melakukan prediksi harga penutupan pada hari berikutnya secara akurat.

3.2. Hasil Prapemrosesan

Sebelum pelatihan model, dilakukan pra-pemrosesan dataset akhir yang mencakup langkah-langkah berikut: Pertama, setelah pengecekan urutan waktu berdasarkan stempel waktu, dipastikan bahwa data masih dalam urutan kronologis. Setelah penghapusan baris terakhir yang memiliki nilai kosong di *close_next_day*, terdapat 2619 observasi (valid) untuk diterapkan dalam eksperimen pembuatan model dengan semua observasi memiliki pasangan fitur-target yang lengkap. Tabel 2 memberikan representasi rinci tentang pembagian data setelah pemrosesan data dengan jumlah dataset pelatihan dan dataset pengujian serta jumlah pembagian internal untuk optimasi parameter PSO. Langkah persiapan yang ketat ini sangat krusial untuk memastikan bahwa model prediktif dapat dilatih menggunakan data berkualitas tinggi tanpa risiko kebocoran data (*data leakage*) antar-garis waktu.

Tabel 2. Pembagian Data

Tahap	Jumlah Data
Data mentah	2620
Data valid setelah penghapusan nilai kosong	2619
Data latih	2095
Data uji	524
Data latih internal untuk PSO	1676

Tabel 2 menunjukkan bahwa sekitar 80% dari seluruh dataset dibagi secara kronologis menjadi 2.095 dataset pelatihan, sedangkan 20% sisanya dibagi menjadi 524 dataset pengujian. Dataset pelatihan kemudian dibagi secara internal dengan rasio 80:20, menghasilkan 1.676 dataset pelatihan internal dan 419 dataset validasi

internal untuk digunakan dalam proses optimasi PSO. Sebagai hasil dari pembagian ini, dataset pengujian tidak disertakan dalam proses pencarian parameter dan dengan demikian model akan dievaluasi menggunakan data yang benar-benar baru.

Baik fitur maupun target dinormalisasi menggunakan *MinMaxScaler* dengan dua scaler (scalerX untuk fitur dan scaler_y untuk target). Scaler tersebut hanya dipasang dan diterapkan pada data pelatihan, tetapi digunakan untuk mentransformasi dataset pengujian dan validasi internal, yang memastikan bahwa kebocoran data tidak akan terjadi.

3.3. Hasil Pelatihan SVR-GridSearch (Baseline Model)

Sebagai model *baseline*, penelitian ini juga menerapkan *Grid Search*, teknik optimasi *hyperparameter* yang menguji secara ekshaustif seluruh kombinasi parameter pada ruang pencarian diskret. Berbeda dengan PSO, *Grid Search* hanya mengevaluasi titik-titik nilai yang telah ditentukan, sehingga kombinasi di antara titik grid tidak pernah diuji.

Ruang pencarian *Grid Search* ditentukan sebagai berikut: $C \in \{0,1; 1; 10; 50; 100\}$, $\epsilon \in \{0,01; 0,05; 0,1\}$, dan $\gamma \in \{0,001; 0,01; 0,1\}$, menghasilkan 45 kombinasi parameter yang diuji menggunakan *GridSearchCV*. Validasi menggunakan skema *PredefinedSplit* pada 419 data validasi internal yang identik dengan skema PSO, dengan MAPE sebagai fungsi objektif. Melalui pengujian menyeluruh terhadap seluruh kombinasi ini, model dapat mengidentifikasi konfigurasi hiperparameter paling optimal yang meminimalkan tingkat kesalahan prediksi pada data yang belum pernah dilihat sebelumnya.

Hasil konfigurasi terbaik dari proses *Grid Search* ditunjukkan pada Tabel 3.

Tabel 3. Konfigurasi dan Hasil Optimasi *Grid Search*

Parameter	Nilai
C	100
ϵ	0.01
γ	0.001
Skema validasi	PredefinedSplit
MAPE validasi	1.99%

Kombinasi parameter terbaik yang ditemukan adalah $C = 100$, $\epsilon = 0,01$, dan $\gamma = 0,001$, dengan MAPE validasi sebesar 1,99%. Hasil ini menunjukkan bahwa konfigurasi parameter tersebut merupakan kombinasi terbaik yang diperoleh dari seluruh ruang pencarian yang telah ditentukan pada proses *Grid Search*. Parameter optimal ini kemudian digunakan untuk membangun model SVR sebagai model *baseline* yang selanjutnya dievaluasi pada data pengujian.

3.4. Optimasi SVR Menggunakan PSO

Optimasi parameter dilakukan melalui *Particle Swarm Optimization* (PSO) untuk menentukan kombinasi optimal tiga parameter SVR, yaitu C, ϵ , dan

γ). Proses optimasi menggunakan dataset pelatihan dan validasi internal, dengan MAPE sebagai fungsi objektif.

Pada tahap awal, PSO membangkitkan sejumlah partikel sebagai kombinasi acak parameter SVR, yang masing-masing dievaluasi untuk memperoleh nilai fitness (MAPE) sebagai dasar penentuan *personal best* (pbest) dan *global best* (gbest). Posisi dan kecepatan partikel kemudian diperbarui pada setiap iterasi menggunakan pbest dan gbest hingga diperoleh kombinasi parameter dengan MAPE terendah.

Konfigurasi PSO yang digunakan, meliputi jumlah partikel, jumlah iterasi, rentang pencarian parameter, dan koefisien PSO, dirangkum pada Tabel 4.

Tabel 4. Konfigurasi Optimasi PSO

Parameter	Nilai
Jumlah partikel	30
Jumlah iterasi	30
Bobot inersia (w)	0,9 - 0,4 (linear decay)
Koefisien kognitif (c1)	1,5
Koefisien sosial (c2)	1,5
Kecepatan maksimum (v_max)	1,0
Rentang pencarian C	0,1 – 501 (skala log10)
Rentang pencarian ϵ	0,001 – 0,501 (skala log10)
Rentang pencarian γ	0,001 – 10 (skala log10)
Fungsi fitness	MAPE pada data validasi internal

Sebagaimana ditunjukkan pada Tabel 4, proses optimasi menggunakan algoritma *Particle Swarm Optimization* (PSO) dijalankan dengan 30 partikel selama 30 iterasi. Setiap partikel merepresentasikan kombinasi nilai parameter SVR yang terdiri atas C, ϵ , dan γ . Bobot inersia diterapkan menggunakan skema *linear decay*, yaitu menurun secara bertahap dari 0,9 menjadi 0,4. Pengaturan ini bertujuan agar proses pencarian dapat melakukan eksplorasi ruang solusi secara lebih luas pada iterasi awal, kemudian beralih menjadi lebih terarah pada iterasi akhir untuk memperoleh kombinasi parameter yang optimal.

Ketiga parameter SVR dicari pada skala logaritmik sehingga rentang nilai yang luas dapat dieksplorasi secara lebih proporsional. Pendekatan ini memungkinkan PSO mengevaluasi berbagai kombinasi parameter secara lebih efektif dibandingkan pencarian pada skala linier. Hasil optimasi parameter SVR menggunakan PSO ditunjukkan pada Tabel 5, dengan kualitas setiap kombinasi parameter dievaluasi berdasarkan nilai *Mean Absolute Percentage Error* (MAPE). Kombinasi parameter yang menghasilkan nilai MAPE terendah kemudian dipilih sebagai parameter terbaik untuk membangun model SVR pada tahap selanjutnya.

Tabel 5. Parameter Terbaik

Parameter	Nilai
-----------	-------

C	501
ϵ	0.001
γ	0.001
MAPE terbaik	1.907%

Kombinasi parameter yang diperoleh menghasilkan MAPE sebesar 1,907%, menunjukkan tingkat kesalahan prediksi yang rendah. Nilai C yang tinggi menunjukkan prioritas tinggi pada kesalahan data pelatihan, sedangkan nilai γ yang kecil menunjukkan kemampuan SVR menggambarkan pola nonlinier dengan akurasi tinggi. Kombinasi optimal ini membuktikan bahwa model memiliki kemampuan generalisasi yang baik dalam memprediksi data baru.

3.5. Evaluasi dan Perbandingan Model

Setelah proses optimasi parameter selesai, model SVR-GridSearch dan SVR-PSO masing-masing dilatih menggunakan seluruh data pelatihan dan dievaluasi pada data uji yang identik. Kinerja kedua model diukur menggunakan empat metrik, yaitu Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), dan Coefficient of Determination (R^2).


Hasil evaluasi model SVR-GridSearch pada data uji disajikan pada Tabel 6.

Tabel 6. Hasil Evaluasi Model SVR-GridSearch

Matriks	SVR-GridSearch
MAE	1,559.87
RMSE	2,128.52
MAPE	1.69%
R^2	0.9809

Hasil evaluasi model SVR-GridSearch seperti yang ditampilkan pada Tabel 6 menghasilkan nilai MAE sebesar 1.559,87, RMSE sebesar 2.128,52, MAPE sebesar 1,69%, dan R^2 sebesar 0,9809 pada data pengujian. Hasil tersebut menunjukkan bahwa model mampu memberikan tingkat akurasi prediksi yang cukup tinggi, ditandai dengan nilai kesalahan prediksi yang relatif rendah serta nilai koefisien determinasi yang mendekati satu. Dengan konfigurasi parameter terbaik yang diperoleh melalui proses *Grid Search*, model telah mampu mengikuti pola pergerakan harga Bitcoin dengan baik meskipun ruang pencarian parameter yang digunakan terbatas pada 45 kombinasi diskret.

Selain dievaluasi menggunakan metrik numerik, performa model SVR-GridSearch juga dianalisis secara visual melalui perbandingan antara nilai aktual dan nilai prediksi pada data pengujian. Visualisasi tersebut disajikan pada Gambar 2.



Gambar 2. Grafik Evaluasi Model SVR-GridSearch


Sebagaimana ditunjukkan pada Gambar 2, garis prediksi SVR-GridSearch mengikuti pola pergerakan harga Bitcoin dengan cukup baik, meski kurang presisi pada pembalikan harga tajam akibat resolusi grid yang terbatas.

Hasil evaluasi model SVR-PSO pada data uji disajikan pada Tabel 7.

Tabel 7. Hasil Evaluasi Model SVR-PSO

Matriks	SVR-PSO
MAE	1,521.47
RMSE	2,101.70
MAPE	1.65%
R ²	0.9813

Model SVR-PSO menghasilkan MAE sebesar 1.521,47, RMSE sebesar 2.101,70, MAPE sebesar 1,65%, dan R² sebesar 0,9813. Nilai ini menunjukkan tingkat kesalahan prediksi yang rendah serta kesesuaian yang baik terhadap data harga BTC aktual pada data uji. Untuk melengkapi hasil evaluasi numerik, performa model SVR-PSO juga divisualisasikan melalui perbandingan antara nilai aktual dan nilai prediksi pada data pengujian. Visualisasi tersebut ditunjukkan pada Gambar 3.



Gambar 3. Grafik Evaluasi Model SVR-PSO

Sebagaimana ditunjukkan pada Gambar 3, garis prediksi SVR-PSO mengikuti pola pergerakan harga Bitcoin secara konsisten dan hampir tumpang tindih dengan nilai aktual pada sebagian besar rentang data pengujian, termasuk pada periode volatilitas tinggi, sehingga menunjukkan kemampuan model dalam mempelajari pola historis harga Bitcoin.

Untuk mengevaluasi efektivitas pendekatan optimasi yang diterapkan, perbandingan performa kedua model


pada data uji disajikan pada Tabel 8 berdasarkan nilai MAE, RMSE, MAPE, dan R².

Tabel 8. Perbandingan Performa Model

Model	MAE	RMSE	MAPE	R ²
SVR-GridSearch	1,559.87	2,128.52	1.69%	0.9809
SVR-PSO	1,521.47	2,101.70	1.65%	0.9813

Model SVR-PSO menghasilkan MAE, RMSE, dan MAPE yang lebih rendah, serta R² yang lebih tinggi dibandingkan SVR-GridSearch. Selisih ini konsisten dengan karakteristik kedua metode: *Grid Search* hanya mengevaluasi 45 kombinasi parameter pada titik-titik diskret, sedangkan PSO melakukan pencarian pada ruang parameter kontinu sehingga berpeluang menemukan kombinasi yang lebih presisi. Dari sisi cakupan pencarian, *Grid Search* hanya mengevaluasi kombinasi pada titik-titik diskret yang telah ditentukan sebelumnya, sedangkan PSO menjelajahi ruang parameter kontinu secara iteratif, sehingga terdapat *trade-off* antara kesederhanaan implementasi dan presisi hasil optimasi.

Setelah masing-masing model dievaluasi secara terpisah, dilakukan perbandingan visual antara hasil prediksi SVR-GridSearch dan SVR-PSO terhadap nilai aktual pada data pengujian. Perbandingan tersebut disajikan pada Gambar 4 untuk memperlihatkan perbedaan kemampuan kedua model dalam mengikuti pola pergerakan harga Bitcoin.



Gambar 4. Perbandingan SVR-GridSearch dengan SVR-PSO

Pada Gambar 4, SVR-PSO menghasilkan prediksi yang lebih mendekati nilai aktual dibandingkan SVR-GridSearch, khususnya pada titik-titik pembalikan arah harga, sejalan dengan hasil evaluasi numerik pada Tabel 8.

4. Kesimpulan

Penelitian ini mengembangkan model *Support Vector Regression* (SVR) yang dioptimalkan menggunakan *Particle Swarm Optimization* (PSO) untuk memprediksi harga Bitcoin berdasarkan data deret waktu historis, dengan optimasi difokuskan pada tiga *hyperparameter* kritis (*C*, *epsilon*, *gamma*) menggunakan Mean Absolute Percentage Error (MAPE) sebagai fungsi objektif. Kombinasi parameter terbaik yang diperoleh adalah *C* = 501, *epsilon* = 0,001, dan *gamma* = 0,001, dengan MAPE validasi sebesar 1,907%. Pada data uji, model ini mencapai MAE 1.521,47, RMSE 2.101,70, MAPE 1,65%, dan R²

0,9813, serta mampu mengikuti pola pergerakan harga Bitcoin yang nonlinier dan volatil secara konsisten, baik pada tren naik maupun turun.

Dibandingkan dengan model *baseline* SVR-GridSearch (MAE 1.559,87; RMSE 2.128,52; MAPE 1,69%; R^2 0,9809), SVR-PSO secara konsisten menghasilkan galat yang lebih rendah dan R^2 yang lebih tinggi, mengonfirmasi bahwa pencarian parameter pada ruang kontinu oleh PSO lebih presisi dibandingkan *Grid Search* yang terbatas pada titik-titik diskret, meskipun *Grid Search* lebih sederhana dari sisi implementasi. Temuan ini menunjukkan bahwa integrasi SVR dan PSO merupakan pendekatan komputasi yang efektif dan efisien untuk mengatasi tantangan volatilitas dan nonlinieritas dalam prediksi harga Bitcoin.

Daftar Rujukan

- [1] Listiani, A., and Al Mahkya, D., 2022. Peramalan Cryptocurrency dengan Autoregressive Integrated Moving Average (ARIMA) dan Risiko Kerugian dengan Value at Risk (VaR). *Journal of Science and Applicative Technology*, 6(2), pp.85–91. <https://doi.org/10.35472/jsat.v6i2.904>
- [2] Melina, M., Sukono, S., Napitupulu, H., Mohamed, N., Chrisnanto, Y. H., Hadiana, A. I., and Kusumaningtyas, V. A., 2025. Cryptocurrency Time Series Forecasting Model Using GRU Algorithm Based on Machine Learning. *BAREKENG: Journal of Mathematics and Its Applications*, 19(2), pp.1317–1328. <https://doi.org/10.30598/barekengvol19iss2pp1317-1328>
- [3] Ramadhan, F. A., and Nathasia, N. D., 2025. Prediksi Harga dan Kinerja Aset Bitcoin Menggunakan Algoritma Long Short-Term Memory. *Jurnal Fasilkom*, 15(1), pp.68–76.
- [4] Wang, Y., Andreeva, G., and Martin-Barragan, B., 2023. Machine learning approaches to forecasting cryptocurrency volatility: Considering internal and external determinants. *International Review of Financial Analysis*, 90, pp.1–21. <https://doi.org/10.1016/j.irfa.2023.102914>
- [5] Brini, A., and Lenz, J., 2024. A comparison of cryptocurrency volatility-benchmarking new and mature asset classes. *Financial Innovation*, 10(1). <https://doi.org/10.1186/s40854-024-00646-y>
- [6] Kukacka, J., and Kristoufek, L., 2023. Fundamental and speculative components of the cryptocurrency pricing dynamics. *Financial Innovation*, 9(1), pp.1–23. <https://doi.org/10.1186/s40854-023-00465-7>
- [7] Nguyen, L. T. M., and Nguyen, P. T., 2024. Determinants of cryptocurrency and decentralized finance adoption - A configurational exploration. *Technological Forecasting and Social Change*, 201, pp.1–19. <https://doi.org/10.1016/j.techfore.2024.123244>
- [8] T. Bagh, M. A. Khan, and K. Iftikhar, "Investor sentiment and cryptocurrency market dynamics: A Vector Autoregressive and Granger causality approach," *Social Sciences and Humanities Open*, vol. 12, Jan. 2025, doi: 10.1016/j.ssaho.2025.102128.
- [9] Bagh, T., Khan, M. A., and Iftikhar, K., 2025. Investor sentiment and cryptocurrency market dynamics: A Vector Autoregressive and Granger causality approach. *Social Sciences & Humanities Open*, 12, pp.1–12. <https://doi.org/10.1016/j.ssaho.2025.102128>
- [10] Kuncara, T., and Anugrah, K. P., 2023. Analisis Volatilitas Cryptocurrency pada Sebelum Pandemi dan pada Saat Pandemi COVID-19 dengan Metode Return pada Bitcoin dan Ethereum. *KEUNIS*, 11(1), pp.86–94. <https://doi.org/10.32497/keunis.v11i1.3981>
- [11] No, J. K. S. D., Ahmed, O. M., and Abdulazeez, A. M., 2025. Comparative Analysis of Machine Learning and Deep Learning Models for Bitcoin Price Prediction. *Indonesian Journal of Computer Science Attribution*, 13(1), pp.407–414.
- [12] Riziq, I. F., and Dzikrillah, A. R., 2024. Implementasi Algoritma LSTM dan SVR untuk Prediksi Harga Bitcoin Menggunakan Data Yahoo Finance. *METIK Jurnal*, 9(2), pp.2025–2032. <https://doi.org/10.47002/metik.v9i2.1077>
- [13] Rahmah, M., Ramadanti, K., and Aulia, I. F., 2026. Perbandingan Algoritma Regresi dalam Memprediksi Penjualan Berdasarkan Indikator Sosial Ekonomi Kabupaten Cirebon (2010–2023). *Jurnal Fasilkom*, 16(1), pp.1–9.
- [14] Ruliana, R., Rais, Z., Marni, M., and Ahmar, A. S., 2024. Implementation of the Support Vector Regression (SVR) Method in Inflation Prediction in Makassar City. *ARRUS Journal of Mathematics and Applied Science*, 4(1), pp.28–35. <https://doi.org/10.35877/mathscience2608>
- [15] Zulmawati, W. S., Ramadanti, K., Syafrandi, S., and Aulia, A. S., 2023. Bitcoin Price Prediction Using Support Vector Regression. *UNP Journal of Statistics and Data Science*, 1(5), pp.488–495. <https://doi.org/10.24036/ujsds/vol1-iss5/121>
- [16] Wu, J., and Wang, Y. G., 2023. A working likelihood approach to support vector regression with a data-driven insensitivity parameter. *International Journal of Machine Learning and Cybernetics*, 14(3), pp.929–945. <https://doi.org/10.1007/s13042-022-01672-x>
- [17] Gananta, I. M., Purnama, I. N., Fredlina, K. Q., and Salma, A., 2023. Optimasi Prediksi Harga Emas dengan Metode Support Vector Regression (SVR) Menggunakan Algoritma Grid Search. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(6), pp.3160–3165.
- [18] Won, J., Lee, H. S., and Lee, J. W., 2025. A review on multi-fidelity hyperparameter optimization in machine learning. *ICT Express*, 11(2), pp.245–257. <https://doi.org/10.1016/j.icte.2025.02.008>
- [19] Purwinarko, A., and Langgundi, F. A., 2023. Crude oil price prediction using Artificial Neural Network-Backpropagation (ANN-BP) and Particle Swarm Optimization (PSO) methods. *Journal of Soft Computing Exploration*, 4(2), pp.99–106. <https://doi.org/10.52465/josce.v4i2.159>
- [20] Ula, M., Ilhadi, V., and Sidek, Z. M., 2024. Comparing Long Short-Term Memory and Random Forest Accuracy for Bitcoin Price Forecasting. *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 23(2), pp.259–272. <https://doi.org/10.30812/matrik.v23i2.3267>
- [21] Kong, X., et al., 2025. Deep learning for time series forecasting: a survey. *International Journal of Machine Learning and Cybernetics*, 16(7–8), pp.5079–5112. <https://doi.org/10.1007/s13042-025-02560-w>
- [22] Casolaro, A., Capone, V., Iannuzzo, G., and Camastra, F., 2023. Deep Learning for Time Series Forecasting: Advances and Open Problems. *Information*, 14(11), p.598. <https://doi.org/10.3390/info14110598>
- [23] Kamisan, N. A. B., Lee, M. H., and Sulandari, W., 2025. Optimizing Train-Test Splits for LSTM and MLP Models in Bitcoin Price Forecasting Accuracy. *Statistika*, 25(2). <https://doi.org/10.29313/statistika.v25i2.6989>
- [24] Grimm, F., Bitsch, G., and van Dinther, C., 2026. The Influence of Preprocessing on Time Series Prediction. *Procedia Computer Science*, 277, pp.739–748. <https://doi.org/10.1016/j.procs.2026.02.115>
- [25] Mulyani, A. S., Mustafid, M., and Widiari, T., 2025. Implementasi Metode Support Vector Regression untuk Prediksi Harga Saham PT. Adaro Energy Tbk. *Jurnal Gaussian*, 14(2), pp.457–468. <https://doi.org/10.14710/j.gauss.14.2.457-468>
- [26] Ferdinand, F., Anthony, R., Winata, T. J., Sutanto, J., Souwiko, R., and Fernando, C., 2025. Comparison of Support Vector Regression and Extreme Learning Machine Methods for Predicting Bitcoin Prices. *Journal of Applied Informatics and Computing*, 9(5), pp.2121–2130. <https://doi.org/10.30871/jaic.v9i5.10983>
- [27] Arsi, P., Wahyudi, R., and Waluyo, R., 2021. Optimasi SVM Berbasis PSO pada Analisis Sentimen Wacana Pindah Ibu Kota Indonesia. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(2), pp.231–237. <https://doi.org/10.29207/resti.v5i2.2698>
- [28] Su, X., Jiang, H., Qin, T., and Lin, G., 2024. Particle Swarm Optimization-Support Vector Regression (PSO-SVR)-Based

-
- Rapid Prediction Method for Radiant Heat Transfer for a Spacecraft Vacuum Thermal Test. *Applied Sciences*, 14(20), p.9407. <https://doi.org/10.3390/app14209407>
- [29] Windy, W., and Prathivi, R., 2025. Komparasi Algoritma Random Forest dan XGBoost dalam Prediksi Premi Asuransi Kesehatan. *Jurnal Transformatika*, 23(1), pp.118–125. <https://doi.org/10.26623/transformatika.v23i1.11914>
- [30] Oprea, S. V., and Băra, A., 2026. Regime-Aware Adaptive Forecasting Framework for Bitcoin Prices Using Probabilistic Generative Models. *Computational Economics*. <https://doi.org/10.1007/s10614-026-11338-3>