

Metode Hybrid SVR-GWO Untuk Prediksi Harga Saham PT. Aneka Tambang Tbk

DOI: <http://dx.doi.org/10.35889/progresif.v22i2.3586>

Creative Commons License 4.0 (CC BY –NC)



Muhammad Aditya Rahman¹, Taghfirul Azhima Yoga Siswa^{2*}, Rofilde Hasudungan³

Teknik Informatika, Universitas Muhammadiyah Kalimantan Timur, Samarinda, Indonesia

*e-mail *Corresponding Author*: tay758@umkt.ac.id

Abstract

Fluctuating and unpredictable stock price movements pose a challenge for investors in their decision-making. This study aims to apply and analyze the performance of a hybrid Support Vector Regression (SVR)–Grey Wolf Optimizer (GWO) model in predicting the stock price of PT Aneka Tambang Tbk. The data used consists of daily stock prices from September 11, 2020, to September 11, 2025, totaling 1,202 data points, with a division of 70% training data and 30% testing data. The research stages include pre-processing, basic SVR modeling, and parameter optimization using GWO. The evaluation was carried out using RMSE, MAE, and MAPE. The results show that GWO optimization improved the model's performance from RMSE 99.78, MAE 55.70, and MAPE 2.61% to RMSE 77.27, MAE 48.97, and MAPE 2.37%. Thus, the SVR–GWO model is capable of improving the accuracy of stock price predictions and has the potential to support investment decision-making.

Keyword: *Grey Wolf Optimizer; Machine Learning; Prediction; Stock Price; Support Vector Regression*

Abstrak

Pergerakan harga saham yang fluktuatif dan sulit diprediksi menjadi tantangan bagi investor dalam pengambilan keputusan. Penelitian ini bertujuan menerapkan dan menganalisis kinerja model *hybrid Support Vector Regression (SVR)–Grey Wolf Optimizer (GWO)* dalam memprediksi harga saham PT Aneka Tambang Tbk. Data yang digunakan berupa harga saham harian periode 11 September 2020 hingga 11 September 2025 sebanyak 1202 data, dengan pembagian 70% data pelatihan dan 30% data pengujian. Tahapan penelitian meliputi *pre-processing*, pemodelan SVR dasar, serta optimasi parameter menggunakan GWO. Evaluasi dilakukan menggunakan RMSE, MAE, dan MAPE. Hasil menunjukkan bahwa optimasi GWO meningkatkan kinerja model dari RMSE 99.78, MAE 55.70, dan MAPE 2.61% menjadi RMSE 77.27, MAE 48.97, dan MAPE 2.37%. Dengan demikian, model SVR–GWO mampu meningkatkan akurasi prediksi harga saham dan berpotensi mendukung pengambilan keputusan investasi.

Kata Kunci: *Grey Wolf Optimizer; Harga Saham; Machine Learning; Prediksi; Support Vector Regression*

1. Pendahuluan

Saham adalah salah satu instrumen keuangan yang paling populer dan diminati oleh masyarakat atau investor untuk berinvestasi di pasar modal. Pergerakan Indeks Harga Saham Gabungan (IHSG) dalam lima tahun terakhir menunjukkan dinamika yang dipengaruhi oleh kondisi ekonomi dan peristiwa global. Pada tahun 2019, IHSG sempat menurun di awal tahun namun kembali stabil pada kisaran 1.58–1.70. Pada tahun 2020, dampak pandemi COVID-19 sangat terasa yang menyebabkan IHSG turun tajam hingga mencapai 1.19 pada bulan Maret, meskipun kemudian perlahan pulih hingga akhir tahun. Pada 2021 kembali pulih dengan stabilitas di kisaran 1.54–1.73, diikuti tren positif pada 2022 meskipun sempat mengalami penurunan di bulan Juni dengan rata-rata 1.75–1.90. Memasuki 2023, meskipun terjadi fluktuasi, IHSG tetap menunjukkan pemulihan dan ditutup pada angka 1.91 pada bulan Desember [1][2].

Analisis perubahan harga saham menggunakan metode perhitungan statistik sederhana masih sering kali mengalami keterbatasan dan tantangan saat diterapkan pada data dengan frekuensi tinggi, sehingga memerlukan analisis yang lebih sistematis [3]. Salah satu cara sistematis yang dapat digunakan yaitu dengan penerapan *Machine Learning (ML)*, yaitu cabang ilmu dari kecerdasan buatan yang memanfaatkan informasi guna menyusun pola matematis lalu dimanfaatkan oleh mekanisme tersebut untuk menghasilkan perkiraan sesuai kumpulan informasi yang tersedia yang telah dikumpulkan dan dipelajari sebelumnya [4]. Beberapa algoritma *machine learning* yang dapat digunakan dalam prediksi harga saham diantaranya *Support Vector Regression (SVR)*, *XGBoost*, *Random Forest (RF)*, *K-Nearest Neighbor (KNN)*, dan *Long Short-Term Memory (LSTM)* [5][6].

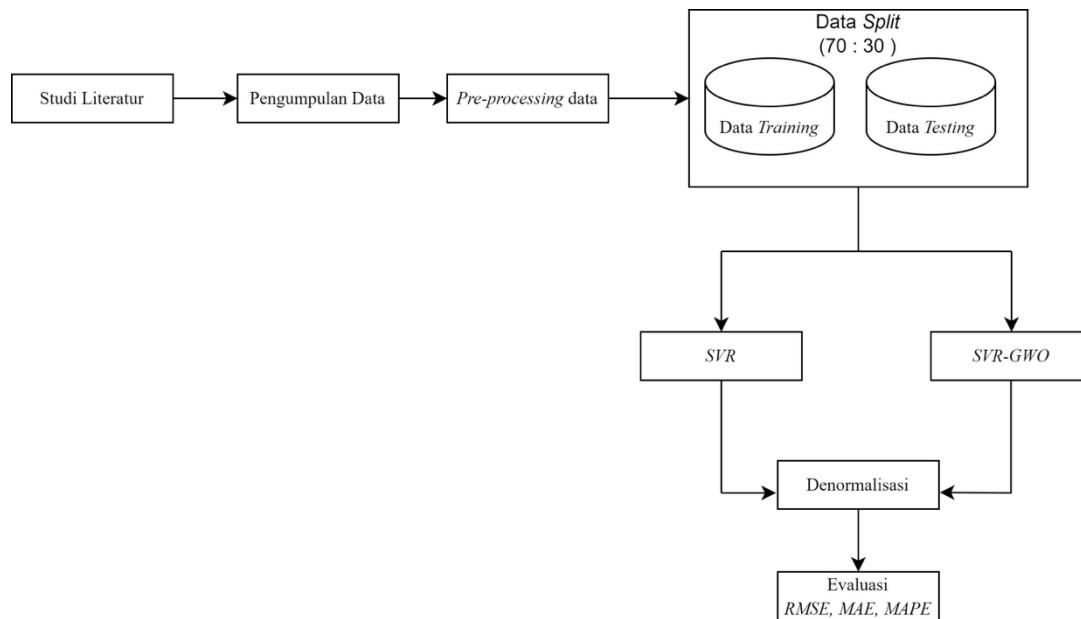
Beberapa penelitian terdahulu yang telah menggunakan algoritma SVR dalam melakukan prediksi harga saham, seperti penelitian tentang prediksi harga saham *Pakistan Stock Exchange* menunjukkan bahwa SVR menghasilkan *RMSE* sebesar 1562.116, *MAE* 1401.253, *MAPE* 2.489, dan R^2 0.976, yang lebih baik dibandingkan *Decision Tree* dengan *RMSE* 13714.49, *MAE* 10790.75, *MAPE* 17.992, dan R^2 0.843, RF dengan *RMSE* 15483.47, *MAE* 12415.67, *MAPE* 20.887, dan R^2 0.864, serta KNN dengan *RMSE* 13955.62, *MAE* 11251.1, *MAPE* 18.924, dan R^2 0.908 [7]. Penelitian lainnya tentang prediksi saham *BBCA*, *TOWR*, dan *PWON* juga menunjukkan bahwa SVR menghasilkan nilai *RMSE* masing-masing sebesar 4.79%, 15.14%, dan 10.61%, serta *MAE* sebesar 3.52%, 13.78%, dan 8.49%, yang lebih unggul dibandingkan RF dengan *RMSE* 6.80%, 20.99%, dan 12.08% serta *MAE* 5.34%, 17.63%, dan 10.17%, dan KNN dengan *RMSE* 6.99%, 23.85%, dan 12.55% serta *MAE* 5.21%, 17.51%, dan 10.38% [8]. Selain itu, terdapat beberapa penelitian yang telah menggunakan algoritma optimasi GWO untuk mengoptimalkan parameter pada model prediksi, seperti penelitian tentang prediksi harga indeks *Bombay Stock Exchange* menggunakan *adaptive GWO-LSTM* menghasilkan nilai *MSE* 0.00152, *RMSE* 0.03909, dan *MAE* 0.02980 [9]. Penelitian lainnya tentang prediksi kekuatan pondasi tiang pancang berbasis batuan menggunakan *SVR-GWO* menghasilkan nilai R^2 0,99598, *MAE* 0,14171, *MSE* 0,034576, *RMSE* 0.18595, dan *MAPE* 0,43233% [10]. Hasil ini cukup baik namun pada kasus yang berbeda. Oleh karena itu, penelitian ini akan menerapkan pendekatan *hybrid SVR-GWO* untuk memprediksi harga saham PT. Aneka Tambang Tbk untuk meningkatkan performa model serta memberikan kontribusi baru dalam penerapan metode optimasi metaheuristik pada prediksi pasar modal.

SVR adalah perluasan dari teknik Support Vector Machine (SVM) yang dirancang khusus untuk menangani kasus regresi, serta memiliki keunggulan dalam hasil prediksi yang luar biasa karena dapat mengatasi masalah *overfitting* [11][12]. Namun, penggunaan SVR memiliki kelemahan dalam memprediksi harga yang kompleks, seperti penelitian tentang prediksi harga *bitcoin* yang menunjukkan penggunaan SVR menghasilkan performa yang kurang baik jika dibandingkan dengan LSTM dengan *MAE* sekitar 6.500–6.900 dan *MSE* di atas 83 juta. Sebaliknya, LSTM lebih akurat dengan *MAE* 1.400–1.700 dan *MSE* 3–5 juta, sehingga peneliti menyarankan untuk menerapkan teknik optimasi *hyperparameter* agar meningkatkan performa prediksi [13].

Beberapa optimasi yang dapat digunakan pada SVR yaitu *Artificial Bee Colony (ABC)*, *Particle Swarm Optimization (PSO)*, *Grey Wolf Optimizer (GWO)*, dan *Genetic Algorithm (GA)* [14]. GWO merupakan algoritma yang bertujuan untuk menemukan nilai minimum atau maksimum dengan memodelkan strategi berburu serigala abu-abu [15]. Penelitian ini akan menerapkan pendekatan SVR-GWO untuk kasus prediksi harga saham, dengan harapan dapat meningkatkan performa model serta memberikan kontribusi baru dalam penerapan metode optimasi metaheuristik pada prediksi pasar modal.

2. Metodologi

Penelitian ini berfokus pada machine learning terkait penerapan algoritma *hybrid SVR-GWO* untuk memprediksi harga saham PT. Aneka Tambang Tbk, dengan tujuan meningkatkan akurasi prediksi dan memberikan insight yang mampu dimanfaatkan sebagai dasar acuan oleh penanam modal dalam menentukan pilihan penanaman dana. Tahapan riset tersebut ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

Berdasarkan Gambar 1, Tahapan penelitian dimulai dengan melakukan studi literatur untuk memperoleh landasan teori dan penelitian terdahulu. Selanjutnya dilakukan pengumpulan data PT. ANTM, kemudian data tersebut melalui tahap *pre-processing* untuk memastikan kualitas dan kelayakan analisis. selanjutnya menerapkan pendekatan *hybrid*, yaitu menggabungkan SVR sebagai model utama dan GWO sebagai metode optimasi parameter. Lalu model di denormalisasi ke dalam skala asli sebelum dievaluasi menggunakan metrik *RMSE*, *MAE*, dan *MAPE*.

2.1 Data Penelitian

Informasi yang dipakai pada kajian ini berupa data runtut waktu harian PT. Aneka Tambang Tbk yang diperoleh dari *investing.com* dari 11 September 2020 sampai 11 September 2025. Data tersebut berjumlah 1202 data dengan tujuh variabel yaitu *Date*, *Close*, *Open*, *High*, *Low*, *Volume*, dan *Perubahan*. Atribut *input* yang digunakan dalam penelitian ini mencakup *Open*, *High*, *Low*, dan *Close* sebagai variabel independen, sedangkan atribut *Close* sebagai variabel dependen atau target harga yang ingin diprediksi. Ilustrasi data riset tersebut disajikan pada Tabel 1.

Tabel 1. Data Saham PT. Aneka Tambang Tbk

<i>Date</i>	<i>Close</i>	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Volume</i>	<i>Perubahan</i>
11/09/2020	775	710	780	700	114.70M	4,73%
14/09/2020	800	780	805	780	61.79M	3,23%
15/09/2020	805	810	820	785	66.31M	0,63%
16/09/2020	795	805	810	785	31.29M	-1,24%
17/09/2020	775	780	805	765	47.54M	-2,52%

2.2 Pre-processing

Pre-processing merupakan serangkaian langkah yang dilakukan untuk membersihkan, menyiapkan, dan mengatur data mentah menjadi format yang sesuai untuk dianalisis lebih lanjut untuk memastikan data yang digunakan dalam analisis memiliki kualitas yang baik dan siap digunakan [16]. beberapa tahapan *pre-processing* yang dilalui pada penelitian ini meliputi data *selection*, data *transformation*, normalisasi data, data *split*, dan *lag-time*.

1) *Data Selection*

Pemilihan Data ialah tahapan penentuan variabel informasi yang sesuai dan diperlukan untuk ditelaah lebih mendalam, sementara variabel yang tidak berkaitan akan dieliminasi [17].

Pada penelitian ini akan menggunakan atribut *Close*, *Open*, *High*, dan *Low*, untuk proses pemodelan, sehingga 3 atribut lainnya yaitu *Date*, *Volume* dan Perubahan akan dihapus.

2) Data Transformation

Transformasi Data merupakan langkah untuk mengonversi nilai variabel yang berbentuk kategori ke dalam format angka yang dapat diolah oleh algoritma *machine learning* untuk memastikan bahwa dataset memenuhi format yang diperlukan untuk analisis dan pelatihan model secara efektif [17].

3) Lag-Time

Lag-Time adalah jumlah pengamatan masa lalu yang harus dipilih secara tepat agar data yang diolah model menjadi relevan dan berkorelasi tinggi dengan nilai yang akan diprediksi, sehingga berpengaruh terhadap akurasi model prediksi *time-series* [18]. Pada penelitian ini akan menggunakan nilai *Lag* sebesar 1.

4) Data Split

Data Split adalah proses membagi kumpulan data menjadi dua kelompok, yakni data pelatihan (training) dan data pengujian (testing). Data pelatihan dimanfaatkan supaya sistem dapat mempelajari pola serta menghasilkan estimasi terhadap informasi baru yang sebelumnya belum pernah dikenali, sedangkan data pengujian dipakai guna mengevaluasi performa model pembelajaran mesin sesudah proses pelatihan dilakukan menggunakan data latih [19]. Pada penelitian ini akan menggunakan rasio pembagian data 70:30.

5) Normalisasi Data

Normalisasi Data merupakan salah satu teknik yang bertujuan untuk menyesuaikan skala nilai atribut sehingga berada dalam rentang tertentu, misalnya antara 0 hingga 1 atau -1 hingga 1. Proses normalisasi ini penting karena perbedaan skala antar fitur dapat memengaruhi kinerja algoritma *machine learning*, dengan data yang telah dinormalkan, model dapat belajar secara lebih efektif dan menghasilkan prediksi yang lebih akurat [20].

2.3 Support Vector Regression (SVR)

Support Vector Regression merupakan salah satu modifikasi dari *SVM* yang berfokus pada pendekatan kasus regresi, *SVR* merupakan teknik *machine learning* yang cocok untuk mengenali data *time-series* karena mempunyai keunggulan dibanding beberapa metode lain atau algoritma lainnya dalam hal pemanfaatan model non-linear atau perubahan yang relatif cepat dari waktu ke waktu [21]. *SVR* sangat cocok dalam membangun model regresi pada data yang mungkin mengandung *noise* atau *outlier* [22]. Perhitungan linear *SVR* dapat dilihat pada Persamaan (1).

$$f(x) = w^T x + b \quad (1)$$

Keterangan:

$f(x)$ = Nilai prediksi atau *output* dari model untuk *input* x .

w = Vektor Bobot.

x = Vektor *Input*.

$w^T x$ = *Dot product* antara bobot dan *input*.

2.4 Grey Wolf Optimizer (GWO)

Grey Wolf Optimizer merupakan algoritma yang mengandalkan hierarki sosial serta pemodelan matematis secara iteratif meningkatkan solusi untuk masalah tertentu berdasarkan kekuatan dan kerja sama antar serigala yang disimulasikan, Pendekatan ini digunakan untuk menemukan solusi berkualitas tinggi untuk masalah optimasi [23]. Terdapat hierarki di antara serigala-serigala ini, dengan *alfa* (α), *beta* (β), *delta* (δ), dan *omega* (ω) yang merepresentasikan empat jenis serigala abu-abu yang digunakan untuk mensimulasikan hierarki kepemimpinan secara matematis [15]. Perhitungan *GWO* dapat dilihat pada Persamaan (2) dan Persamaan (3).

$$\vec{D} = \left| \vec{C} \overline{X_p(t)} - \overline{X(t)} \right| \quad (2)$$

$$\overrightarrow{X(t+1)} = \left| \overrightarrow{X_p(t)} - \overrightarrow{DA} \right| \tag{3}$$

Keterangan:

- \overrightarrow{D} = Vektor jarak antara agen dan mangsa.
- \overrightarrow{C} = Vektor koefisien acak, digunakan untuk mengatur dinamika pencarian.
- $\overrightarrow{X_p(t)}$ = Posisi target atau mangsa pada iterasi t .
- $\overrightarrow{X_t(t)}$ = Posisi agen pencari pada iterasi t .
- $\overrightarrow{X}(t+1)$ = Posisi agen pada iterasi berikutnya.
- $\overrightarrow{X_p(t)}$ = Posisi target atau mangsa pada iterasi t .
- \overrightarrow{A} = Vektor koefisien, mengontrol langkah pergerakan agen.

Proses perburuan oleh agen pencari akan berakhir ketika mangsa berhenti bergerak, yang menandai fase serangan terhadap mangsa, yang dapat dilihat pada Persamaan (4) sampai Persamaan (9).

$$\overrightarrow{D_\alpha} = \left| \overrightarrow{C_1} \cdot \overrightarrow{X_\alpha} - \overrightarrow{X} \right| \tag{4}$$

$$\overrightarrow{D_\beta} = \left| \overrightarrow{C_2} \cdot \overrightarrow{X_\beta} - \overrightarrow{X} \right| \tag{5}$$

$$\overrightarrow{D_\delta} = \left| \overrightarrow{C_3} \cdot \overrightarrow{X_\delta} - \overrightarrow{X} \right| \tag{6}$$

$$\overrightarrow{X_1} = \overrightarrow{X_\alpha} - \overrightarrow{A_1} \cdot \overrightarrow{D_\alpha} \tag{7}$$

$$\overrightarrow{X_2} = \overrightarrow{X_\beta} - \overrightarrow{A_2} \cdot \overrightarrow{D_\beta} \tag{8}$$

$$\overrightarrow{X_3} = \overrightarrow{X_\delta} - \overrightarrow{A_3} \cdot \overrightarrow{D_\delta} \tag{9}$$

Keterangan :

- \overrightarrow{X} = posisi serigala (agen pencarian) saat ini.
- $\overrightarrow{X_\alpha}$ = Posisi serigala *alpha* (pimpinan kawan).
- $\overrightarrow{X_\beta}$ = posisi serigala *beta*.
- $\overrightarrow{X_\delta}$ = posisi serigala *delta*.
- $\overrightarrow{D_\alpha}$ = jarak antara posisi serigala saat ini dengan serigala *alpha*.
- $\overrightarrow{D_\beta}$ = jarak antara posisi serigala saat ini dengan serigala *beta*.
- $\overrightarrow{D_\delta}$ = jarak antara posisi serigala saat ini dengan serigala *omega*.
- $\overrightarrow{X_1}$ = estimasi posisi mangsa berdasarkan serigala *alpha*.
- $\overrightarrow{X_2}$ = estimasi posisi mangsa berdasarkan serigala *beta*.
- $\overrightarrow{X_3}$ = estimasi posisi mangsa berdasarkan serigala *delta*.
- $\overrightarrow{C_{1,2,3}}$ = vektor koefisien acak yang mengatur pengaruh posisi pemimpin.
- $\overrightarrow{A_{1,2,3}}$ = vektor koefisien yang mengatur arah dan besar pergerakan serigala.

Posisi agen pencarian pada iterasi berikutnya diperoleh dengan menghitung rata-rata ketiga posisi tersebut, yang dapat dilihat pada Persamaan (10).

$$\overrightarrow{X}(t+1) = \frac{\overrightarrow{X_1}}{3} + \frac{\overrightarrow{X_2}}{3} + \frac{\overrightarrow{X_3}}{3} \tag{10}$$

Keterangan:

- \vec{X} = posisi serigala (agen pencarian) saat ini.
 $t + 1$ = posisi serigala pada iterasi berikutnya.
 $\overline{X_1}$ = estimasi posisi mangsa berdasarkan serigala *alpha*.
 $\overline{X_2}$ = estimasi posisi mangsa berdasarkan serigala *beta*.
 $\overline{X_3}$ = estimasi posisi mangsa berdasarkan serigala *delta*.

2.5 Denormalisasi

Denormalisasi merupakan sebuah proses untuk mengembalikan nilai yang telah dinormalisasi menjadi ke dalam bentuk skala aslinya, sehingga data tersebut dapat dianalisis sesuai dengan nilai sebenarnya [24].

2.6 Evaluasi

Tahap evaluasi terhadap model dilakukan guna menilai kinerja algoritma untuk melihat seberapa baik model mampu memprediksi data baru untuk membandingkan kelebihan dan kekurangan pada algoritma [25]. Pada penelitian ini akan menggunakan 3 model evaluasi yaitu *RMSE*, *MAE*, dan *MAPE*, matriks evaluasi ini digunakan untuk mengukur seberapa besar perbedaan antara hasil prediksi dengan data aktual serta menilai tingkat efisiensi model [26].

1. Root Mean Square Error (RMSE)

MAPE merupakan rata-rata kesalahan antara aktual dan prediksi dalam bentuk persentase, yang menghitung rata-rata perbedaan persentase absolut antara aktual dan prediksi [27]. Berikut perhitungan *MAPE* dapat dilihat pada Persamaan (11).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (11)$$

Keterangan:

- N = Jumlah total data pada pengamatan.
 y_i = Nilai aktual pada data ke i .
 \bar{y}_i = Nilai prediksi pada data ke i .
 $(y_i - \bar{y}_i)^2$ = Kuadrat selisih antara nilai aktual dan prediksi.

2. Mean Absolute Error (MAE)

MAE digunakan untuk menghitung rata-rata deviasi absolut, yaitu kesalahan rata-rata prediksi. *MAE* kurang dipengaruhi oleh *outlier*, dan *MAE* yang lebih rendah berarti akurasi yang lebih tinggi jika dibandingkan dengan *RMSE* dan *MSE* [28]. Berikut perhitungan *MAE* dapat dilihat pada Persamaan (12).

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \bar{y}_i| \quad (12)$$

Keterangan:

- N = Jumlah total data pada pengamatan.
 y_i = Nilai aktual pada data ke i .
 \bar{y}_i = Nilai prediksi pada data ke i .
 $|y_i - \bar{y}_i|$ = Nilai absolut dari selisih antara nilai aktual dan prediksi.

3. Mean Absolute Percentage Error (MAPE)

MAPE merupakan rata-rata kesalahan antara aktual dan prediksi dalam bentuk persentase, yang menghitung rata-rata perbedaan persentase absolut antara aktual dan prediksi [27]. Berikut perhitungan MAPE dapat dilihat pada Persamaan (13).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \bar{y}_i}{y_i} \right| \tag{13}$$

Keterangan :

N = Jumlah total data pada pengamatan.

y_i = Nilai aktual pada data ke $- i$.

\bar{y}_i = Nilai prediksi pada data ke $- i$.

$\frac{|y_i - \bar{y}_i|}{y_i}$ = Persentase selisih absolut antara nilai aktual dan prediksi.

3. Hasil dan Pembahasan

3.1 Penerapan Algoritma SVR

1. Pengujian Parameter C

Pengujian parameter regulasi (C) dilakukan untuk mengetahui nilai parameter yang paling optimal dalam mengatur keseimbangan tingkat kesalahan prediksi dan kompleksitas model. Hasil pengujian dapat dilihat pada Tabel 2.

Tabel 2. Pengujian Parameter C

Range C	RMSE	MAE	MAPE
1-10	66.45	41.93	2.01%
10-100	65.90	41.50	1.99%
100-200	65.58	41.40	1.98%
200-300	65.51	41.37	1.98%
300-400	65.48	41.37	1.98%
400-500	65.47	41.39	1.98%
500-600	65.59	41.71	2.01%
600-700	65.57	41.70	2.01%
700-800	65.76	41.89	2.02%
800-900	66.04	42.29	2.05%
900-1000	66.35	42.68	2.09%

Berdasarkan Tabel 2, menunjukkan hasil pengujian batas parameter C paling optimal diperoleh pada range 400-500 dengan nilai RMSE paling rendah yang menunjukkan kinerja model paling optimal dibanding range lainnya.

2. Pengujian Parameter Epsilon (ε)

Pengujian parameter ε dilakukan untuk menentukan tingkat toleransi kesalahan yang paling optimal pada model SVR. Hasil pengujian dapat dilihat pada Tabel 3.

Tabel 3. Pengujian Epsilon (ε)

Range ε	RMSE	MAE	MAPE
0.0001-0.001	67.67	43.14	2.07%
0.001-0.01	67.53	43.17	2.08%
0.0001-0.01	67.62	43.16	2.08%
0.0001-0.1	67.81	43.67	2.11%
0.001-0.1	70.93	48.11	2.41%
0.001-1.0	11.64	86.35	4.69%

Berdasarkan Tabel 3 menunjukkan hasil pengujian batas parameter ε paling optimal diperoleh pada range 0.001-0.01, yang menunjukkan kinerja model paling optimal dibanding range lainnya. Hasil ini menggambarkan bahwa toleransi kesalahan pada rentang tersebut

memberikan keseimbangan yang optimal bagi model dalam mempelajari pola data tanpa mengabaikan kesalahan yang signifikan.

3. Pengujian Parameter γ

Pengujian parameter γ dilakukan untuk menentukan tingkat pengaruh fungsi kernel terhadap pola data pada model SVR. Hasil pengujian dapat dilihat pada Tabel 4.

Tabel 4. Pengujian γ

Range γ	RMSE	MAE	MAPE
0.001–0.01	78.86	52.75	2.68%
0.001–0.1	75.37	49.67	2.48%
0.01–1.0	68.01	43.27	2.07%
0.1–1.0	66.38	42.05	2.02%
0.001–1.0	74.98	49.33	2.48%
0.01–2.0	68.07	43.35	2.08%
0.001–2.0	72.86	47.54	2.35%
0.1–2.0	66.17	41.86	2.01%

Pada tabel 4. menunjukkan hasil pengujian batas parameter γ paling optimal diperoleh pada *range* 0.1-2.0, yang menunjukkan kinerja model paling optimal dibanding *range* lainnya. Hasil ini menunjukkan bahwa pengaruh fungsi kernel pada rentang tersebut mampu menangkap pola *non-linear* data secara paling efektif, sehingga dipilih sebagai parameter *gamma* terbaik pada tahap pemodelan selanjutnya.

4. Evaluasi Model SVR

Setelah menetapkan rentang parameter terbaik yang akan digunakan, selanjutnya model SVR digunakan untuk memprediksi harga saham PT. Aneka Tambang menggunakan data *train* untuk membangun serta melatih model dan data *testing* untuk mengevaluasi hasil performa prediksi. Berikut hasil evaluasi dari model dasar SVR dapat dilihat pada tabel 5.

Tabel 5. Evaluasi Model SVR

RMSE	MAE	MAPE
99.78	55.70	2.61%

3.2 Penerapan Optimasi GWO

1) Pengujian Jumlah Serigala

Pengujian jumlah serigala pada optimasi GWO dilakukan untuk mengetahui pengaruhnya terhadap kinerja optimasi parameter SVR. Pengujian ini dilakukan guna memperoleh jumlah serigala yang optimal. Berikut jumlah serigala yang digunakan dalam pengujian dapat dilihat pada Tabel 6.

Tabel 6. Pengujian Jumlah Serigala

Jumlah Serigala	RMSE	MAE	MAPE
5	131.02	64.05	2.85%
10	130.80	63.86	2.84%
25	132.46	64.20	2.84%
20	132.72	64.40	2.85%
30	126.51	62.85	2.81%
40	131.13	64.14	2.85%

Pada Tabel 6 menunjukkan hasil pengujian jumlah serigala. Jumlah serigala sebanyak 30 menghasilkan nilai *RMSE*, *MAE*, dan *MAPE* paling optimal dibandingkan jumlah serigala lainnya. Hasil ini menunjukkan bahwa jumlah serigala sebanyak 30 mampu memberikan keseimbangan yang optimal antara eksplorasi dan eksploitasi dalam proses optimasi GWO.

2) Pengujian Iterasi

Pengujian iterasi dilakukan untuk menentukan jumlah iterasi yang optimal agar proses optimasi dapat mencapai konvergensi tanpa meningkatkan waktu komputasi secara berlebihan. Berikut jumlah iterasi yang digunakan dalam pengujian dapat dilihat Pada Tabel 7.

Tabel 7. Pengujian Iterasi

Jumlah Iterasi	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
10	131.02	64.05	2.85%
20	131.64	64.11	2.85%
30	132.72	64.40	2.85%
40	130.23	63.83	2.84%
50	132.44	64.39	2.86%
60	129.22	63.50	2.83%
80	133.59	64.60	2.86%

Pada Tabel 7 menunjukkan hasil pengujian jumlah iterasi, jumlah iterasi sebanyak 60 menghasilkan nilai *RMSE*, *MAE*, dan *MAPE* yang paling rendah dibandingkan jumlah iterasi lainnya, sehingga menunjukkan bahwa proses optimasi telah mencapai kinerja yang optimal pada jumlah iterasi tersebut.

3) Pengujian *Bounds*

pengujian batas atas (*upper bounds*) dan batas bawah (*lower bounds*) dilakukan untuk membatasi ruang pencarian solusi agar proses optimasi berjalan stabil dan menghasilkan parameter yang realistis serta optimal. Penentuan parameter *C*, *epsilon* (ϵ), dan *gamma* (γ) pada penelitian ini akan mengacu pada nilai terbaik yang diperoleh dari pengujian rentang *SVR* sebelumnya. Dengan menggunakan Jumlah populasi serigala sebanyak 30 dan iterasi sebanyak 60, hasil pengujian *bounds* dapat dilihat pada Tabel 8.

Tabel 8. Pengujian *Bounds*

Parameter	<i>Lower Bounds</i>	<i>Upper Bounds</i>	<i>Best Params</i>
<i>C</i>	400	500	500
<i>epsilon</i> (ϵ)	0.001	0.01	0.00921178
<i>gamma</i> (γ)	0.1	2.0	0.5

Pada Tabel 8 menampilkan rentang batas bawah dan batas atas parameter yang digunakan dalam proses optimasi, yaitu *C* (400–500), *epsilon* (0,001–0,01), dan *gamma* (0,1–2,0). Berdasarkan pengujian, diperoleh parameter terbaik yaitu *C* sebesar 500, *epsilon* sebesar 0,00921178, dan *gamma* sebesar 0,5, yang seluruhnya berada dalam rentang batas yang telah ditentukan.

4) Evaluasi Model *SVR-GWO*

Setelah menetapkan parameter terbaik yang akan digunakan untuk optimasi, model *hybrid SVR-GWO* diterapkan untuk memprediksi harga saham PT Aneka Tambang Tbk. Berikut adalah hasil evaluasi dari model *SVR-GWO* yang telah dioptimasi dapat dilihat pada Tabel 9.

Tabel 9. Evaluasi Model *SVR-GWO*

<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
77.27	48.97	2.37%

3.3 Perbandingan Hasil Evaluasi

Perbandingan hasil evaluasi dilakukan untuk mengetahui perbedaan kinerja performa antara model *SVR* dan model *hybrid SVR-GWO* dalam memprediksi harga saham PT. Aneka Tambang Tbk. Perbandingan hasil evaluasi dapat dilihat pada Tabel 10.

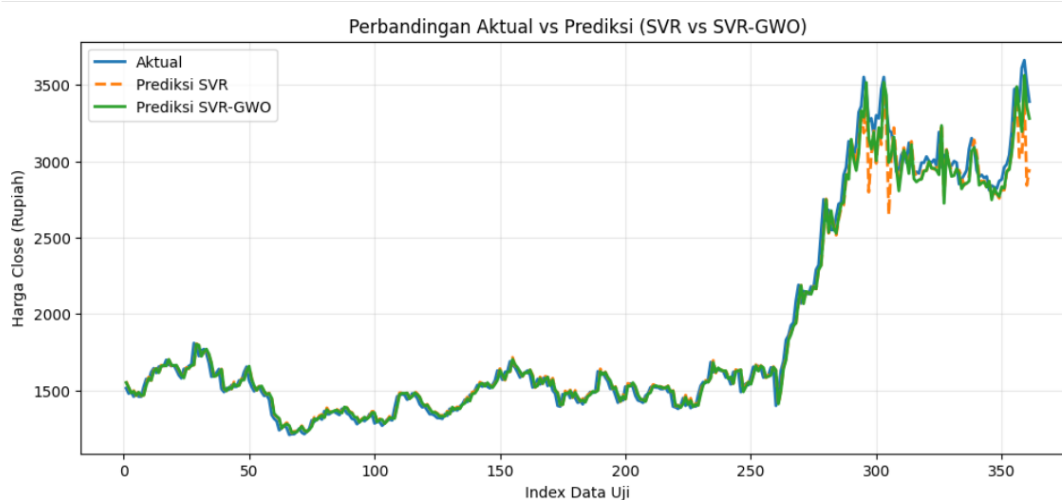
Tabel 10. Perbandingan Hasil Evaluasi

Model	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
<i>SVR</i>	99.78	55.70	2.61%
<i>SVR-GWO</i>	77.27	48.97	2.37%

Untuk mengevaluasi kemampuan model dalam menghasilkan prediksi yang akurat, dilakukan perbandingan antara nilai aktual dan nilai prediksi yang dihasilkan oleh model *SVR* dan *SVR-GWO* pada data uji (*testing*). Contoh hasil prediksi tersebut disajikan pada Tabel 11 dan Gambar 2.

Tabel 11. Tabel Perbandingan Hasil Prediksi Aktual dan Model

Data Aktual	Prediksi Model SVR	Prediksi Model SVR-GWO
1515	1560.25	1536.20
1480	1517.89	1515.21
1490	1483.59	1476.06
1460	1499.32	1480.74
1480	1465.52	1459.74
1460	1493.84	1472.21
1460	1464.65	1458.64
1525	1469.82	1456.59
1575	1545.56	1513.47
1565	1587.51	1564.12

**Gambar 2.** Grafik Perbandingan Hasil Prediksi

Berdasarkan Gambar 2, terlihat bahwa model *hybrid SVR-GWO* memiliki kemampuan yang lebih baik dalam mengikuti pergerakan harga saham aktual dibandingkan dengan model SVR dasar. Hal ini menunjukkan bahwa algoritma optimasi *GWO* dapat meningkatkan akurasi model prediksi SVR, terutama dalam menangkap tren harga yang tajam dan fluktuatif. Pada awal periode, perbedaan antara prediksi dan harga aktual tidak terlalu signifikan untuk kedua model, tetapi seiring dengan waktu dan terjadinya pergerakan harga yang lebih volatil, model SVR menunjukkan ketidakmampuan dalam mengikuti pergerakan harga yang lebih tajam. Sebaliknya, model SVR-GWO mampu menyesuaikan diri lebih baik, dengan prediksi yang lebih mendekati harga aktual, meskipun masih ada beberapa titik di mana ketepatan prediksi dapat ditingkatkan.

3.4 Pembahasan

Penelitian ini menggunakan model *hybrid Support Vector Regression – Grey Wolf Optimizer* untuk memprediksi harga saham PT. Aneka Tambang Tbk. Data yang digunakan diperoleh dari situs *investing.com* dengan rentang waktu dari 11 September 2020 sampai 11 September 2025 dengan jumlah data sebanyak 1202 baris. Proses penelitian meliputi beberapa tahapan penting, mulai dari studi literatur, pengumpulan data, *pre-processing*, pemodelan SVR dan SVR-GWO, serta evaluasi model. Hasil penelitian menunjukkan bahwa penerapan metode *hybrid SVR-GWO* mampu meningkatkan akurasi prediksi harga saham secara signifikan dibandingkan dengan model SVR. Hal ini dapat dilihat dari penurunan nilai error pada ketiga metrik evaluasi yang digunakan. Model SVR dasar menghasilkan nilai *RMSE* sebesar 99.78, *MAE* sebesar 55.70, dan *MAPE* sebesar 2.61%, sedangkan setelah dilakukan optimasi menggunakan *GWO*, nilai error menurun menjadi *RMSE* sebesar 77.27, *MAE* sebesar 48.97, dan *MAPE* sebesar 2.37%. Penurunan nilai *RMSE* sebesar 22.51 menunjukkan bahwa model SVR-GWO mampu mengurangi kesalahan prediksi secara signifikan. Selain itu, penurunan nilai *MAE* sebesar 6.73 menunjukkan bahwa secara rata-rata kesalahan absolut prediksi juga mengalami penurunan. Sementara itu, penurunan nilai *MAPE* sebesar 0.24% menunjukkan peningkatan

akurasi dalam bentuk persentase, yang mengindikasikan bahwa model SVR-GWO lebih konsisten dalam memprediksi harga saham dibandingkan model SVR dasar.

Peningkatan performa ini terjadi karena Grey Wolf Optimizer mampu menemukan kombinasi parameter optimal pada SVR, yaitu nilai C sebesar 500, epsilon sebesar 0.0092, dan gamma sebesar 0.5. Parameter tersebut berperan penting dalam mengatur kompleksitas model, toleransi kesalahan, serta kemampuan kernel dalam menangkap pola non-linear. Dengan parameter yang optimal, model SVR menjadi lebih mampu dalam menangkap pola fluktuatif pada data time series harga saham. Jika dilihat dari hasil prediksi, model SVR-GWO juga menunjukkan kemampuan yang lebih baik dalam mengikuti pergerakan harga saham aktual dibandingkan model SVR dasar. Hal ini terutama terlihat pada kondisi fluktuasi tinggi, di mana model SVR cenderung menghasilkan prediksi yang lebih jauh dari nilai aktual, sedangkan model SVR-GWO mampu menghasilkan prediksi yang lebih mendekati nilai sebenarnya.

Temuan dalam penelitian ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa penggunaan algoritma optimasi seperti *Grey Wolf Optimizer* dapat meningkatkan performa model *machine learning*. Seperti penelitian tentang prediksi kekuatan tiang pancang berbasis batuan yang menunjukkan peningkatan menggunakan model SVR-GWO dengan nilai RMSE dari 2.5374 menjadi 0.18595, MAE dari 2.141 menjadi 0.14171 dan MAPE dari 6.9543% menjadi 0.43233% [10]. Selain itu penelitian tentang prediksi harga bawang merah menggunakan model SVR-GWO juga menunjukkan penurunan nilai RMSE dari 766.14 menjadi 609.97 [29]. Oleh karena itu, dapat disimpulkan bahwa model *hybrid SVR-GWO* memberikan kontribusi positif dalam meningkatkan performa model prediksi harga saham PT. Aneka Tambang Tbk, yang menunjukkan hasil yang lebih optimal dibanding model SVR dasar. Hasil penelitian ini memperkuat bahwa pendekatan hybrid antara model prediksi dan algoritma optimasi mampu menghasilkan model dengan tingkat akurasi yang lebih tinggi dibandingkan metode tunggal.

Meskipun demikian, penelitian ini masih memiliki keterbatasan, yaitu hanya menggunakan satu jenis algoritma optimasi dan satu objek saham. Oleh karena itu, penelitian selanjutnya disarankan untuk membandingkan metode optimasi lain seperti *Particle Swarm Optimization (PSO)* dan *Genetic Algorithm (GA)*, serta menggunakan dataset yang lebih beragam untuk meningkatkan generalisasi model.

4. Simpulan

Berdasarkan hasil penelitian yang dilakukan, dapat disimpulkan bahwa penerapan model *hybrid SVR-GWO* untuk prediksi harga saham PT Aneka Tambang Tbk berhasil diterapkan melalui beberapa tahapan, mulai dari pengumpulan data, *pre-processing*, hingga implementasi model. Model SVR dasar menghasilkan RMSE 99.78, MAE 55.70, dan MAPE 2.61%. setelah diterapkan optimasi GWO, nilai RMSE turun menjadi 77.27, MAE menjadi 48.97, dan MAPE menjadi 2.37%, yang menunjukkan penurunan kesalahan prediksi dan peningkatan akurasi. Dengan demikian, dapat disimpulkan bahwa penambahan metode optimasi GWO pada model SVR memberikan kontribusi dalam meningkatkan performa prediksi harga saham. Untuk penelitian selanjutnya, disarankan untuk membandingkan *Grey Wolf Optimizer* dengan metode optimasi lain seperti *PSO*, *GA*, ataupun optimasi lainnya sehingga dapat mengetahui kelebihan dan kekurangan masing-masing metode dalam optimasi parameter model dan dapat memilih algoritma optimasi yang cocok.

Daftar Referensi

- [1] I. Sukartaatmadja, S. Khim, and M. N. Lestari, "Faktor-faktor Yang Mempengaruhi Harga Saham Perusahaan," *J. Ilm. Manaj. Kesatuan*, vol. 11, no. 1, pp. 21–40, 2023, doi: 10.37641/jimkes.v11i1.1627.
- [2] Amelya Rosalina Siringoringo *et al.*, "Analisis Pengaruh BI Rate dan Inflasi Terhadap Indeks Harga Saham Gabungan Di Indonesia Periode 2019-2023: Studi Dengan Model VAR," *EKOMA J. Ekon. Manajemen, Akunt.*, vol. 4, no. 3, pp. 5483–5490, 2025, doi: 10.56799/ekoma.v4i3.7227.
- [3] J. Bao and T. Morimoto, "Machine Learning with Applications High-frequency stock price prediction via deep learning," *Mach. Learn. with Appl.*, vol. 21, no. April, p. 100716, 2025, doi: 10.1016/j.mlwa.2025.100716.
- [4] F. Nur Fajri, A. Tholib, and W. Yuliana, "Application of Machine Learning Algorithm for Determining Elective Courses in Informatics Study Program," *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 3, pp. 485–496, 2022, doi: 10.28932/jutisi.v8i3.3990.

- [5] L. Gao, Y. Shangguan, Z. Sun, Q. Shen, and Z. Shi, "Estimation of Non-Optically Active Water Quality Parameters in Zhejiang Province Based on Machine Learning," *Remote Sens.*, vol. 16, no. 3, pp. 1–19, 2024, doi: 10.3390/rs16030514.
- [6] A. K. Yadav and V. P. Vishwakarma, "An Integrated Blockchain Based Real Time Stock Price Prediction Model by CNN, Bi LSTM and AM," *Procedia Comput. Sci.*, vol. 235, no. 2023, pp. 2630–2640, 2024, doi: 10.1016/j.procs.2024.04.248.
- [7] D. S. Metwally, M. Ali, S. M. Alghamdi, and D. M. Khan, "A novel hybrid model to forecast the stock price based on CEEMDAN and support vector regression," *J. Radiat. Res. Appl. Sci.*, vol. 18, no. 2, p. 101385, 2025, doi: 10.1016/j.jrras.2025.101385.
- [8] S. A. Amellia Khariis, A. H. Anna Zili, M. Malik, W. Nuryaningrum, and A. Putri, "Comparing machine learning models for Indonesia stock market prediction," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 38, no. 1, p. 508, 2025, doi: 10.11591/ijeecs.v38.i1.pp508-516.
- [9] P. Gupta, S. K. Gupta, and R. S. Jadon, "Adaptive Grey Wolf Optimization Technique for Stock Index Price Prediction on Recurring Neural Network Variants," *Int. J. Recent Innov. Trends Comput. Commun.*, vol. 11, no. 11s, pp. 309–318, 2023, doi: 10.17762/ijritcc.v11i11s.8103.
- [10] Z. Sun, F. Liu, Y. Han, and R. Min, "Prediction of ultimate bearing capacity of rock-socketed piles based on GWO-SVR algorithm," *Structures*, vol. 61, no. January, p. 106039, 2024, doi: 10.1016/j.istruc.2024.106039.
- [11] S. Shafiee, L. M. Lied, I. Burud, J. A. Dieseth, M. Alsheikh, and M. Lillemo, "Sequential forward selection and support vector regression in comparison to LASSO regression for spring wheat yield prediction based on UAV imagery," *Comput. Electron. Agric.*, vol. 183, no. 1432, p. 106036, 2021, doi: 10.1016/j.compag.2021.106036.
- [12] Y. Sun, S. Mutalib, Omar, and Peng, "Research on Stock Prediction Model using Mode Decomposition Algorithm and Support Vector Regression," in *Proceedings of the 2024 Guangdong-Hong Kong-Macao Greater Bay Area International Conference on Digital Economy and Artificial Intelligence*, New York, NY, USA: ACM, Jan. 2024, pp. 378–384. doi: 10.1145/3675417.3675480.
- [13] I. F. Riziq and A. R. Dzikrillah, "Impelementasi Algoritma LSTM Dan SVR Untuk Prediksi Harga Bitcoin Menggunakan Data Yahoo Finance," pp. 284–291, 2025, doi: 10.47002/metik.v9i2.1077.
- [14] J. Ma *et al.*, "Metaheuristic-based support vector regression for landslide displacement prediction: a comparative study," *Landslides*, vol. 19, no. 10, pp. 2489–2511, 2022, doi: 10.1007/s10346-022-01923-6.
- [15] İ. Tuğal, "Energy efficiency in building: Entropy-based Grey Wolf Optimization for improved MLP performance," *Energy Reports*, vol. 13, no. December 2024, pp. 4247–4260, 2025, doi: 10.1016/j.egyr.2025.03.048.
- [16] M. Munawaroh, T. Azhima, Y. Siswa, and W. J. Pranoto, "Optimasi Metode BMR dan Simulated Annealing untuk Algoritma SVM dalam Mengatasi Imbalanced dan High Dimensional Data Stunting," vol. 05, no. 3, pp. 1–19, 2024, [Online]. Available: <https://ijurnal.com/1/index.php/jpip>
- [17] Siti Muawwanah, T. A. Y. Siswa, and Wawan Joko Pranoto, "Model Optimasi SVM-GSBE dalam Menangani High Dimensional Data Stunting Kota Samarinda," *J. Teknol. Sist. Inf. dan Apl.*, vol. 7, no. 3, pp. 1246–1258, 2024, doi: 10.32493/jtsi.v7i3.41545.
- [18] O. Surakhi *et al.*, "Time-lag selection for time-series forecasting using neural network and heuristic algorithm," *Electron.*, vol. 10, no. 20, pp. 1–22, 2021, doi: 10.3390/electronics10202518.
- [19] F. Putra, H. F. Tahiyat, R. M. Ihsan, Rahmaddeni, and L. Efrizoni, "Application of K-Nearest Neighbor Algorithm Using Wrapper as Preprocessing for Determination of Human Weight Information," *2024 IEEE 5th Int. Conf. Conver. Technol. I2CT 2024*, vol. 4, no. January, pp. 273–281, 2024, doi: 10.1109/I2CT45611.2019.9033691.
- [20] A. Widyanto, K. Kusriani, and K. Kusnawi, "Pengaruh Keseimbangan Data terhadap Akurasi Model Support Vector Machine pada Data Set Donor Darah," *J. Teknol. Terpadu*, vol. 9, no. 2, pp. 79–88, 2023, doi: 10.54914/jtt.v9i2.771.
- [21] N. M. Aruan, G. W. Simanjuntak, and A. I. Siagian, "Pendekatan Algoritma Support Vector Regression Dalam Memprediksi Harga Cryptocurrency (Studi Kasus: Binance)," *J. Tek. Inform. dan Sist. Inf.*, vol. 10, no. 3, pp. 531–541, 2023, [Online]. Available: <http://jurnal.mdp.ac.id>

- [22] Z. Qi, Y. Feng, S. Wang, and C. Li, "Enhancing hydropower generation Predictions: A comprehensive study of XGBoost and Support Vector Regression models with advanced optimization techniques," *Ain Shams Eng. J.*, vol. 16, no. 1, p. 103206, 2025, doi: 10.1016/j.asej.2024.103206.
- [23] S. Sharma and I. Ali, "Efficient energy management and cost optimization using multi-objective grey wolf optimization for EV charging/discharging in microgrid," *e-Prime - Adv. Electr. Eng. Electron. Energy*, vol. 10, no. 2023, p. 100804, Dec. 2024, doi: 10.1016/j.prime.2024.100804.
- [24] Z. Annisa, N. Azizah, I. Cholissodin, and L. Muflikhah, "Prediksi Hasil Panen Tanaman Biofarmaka di Indonesia dengan Menggunakan Metode Extreme Learning Machine," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 11, pp. 5331–5338, 2022.
- [25] K. H. Suradiradja, "Algoritme Machine Learning Multi-Layer Perceptron dan Recurrent Neural Network untuk Prediksi Harga Cabai Merah Besar di Kota Tangerang," *Fakt. Exacta*, vol. 14, no. 4, p. 194, 2022, doi: 10.30998/faktorexacta.v14i4.10376.
- [26] E. Ofori-Ntow Jnr, Y. Y. Ziggah, M. J. Rodrigues, and S. Relvas, "A hybrid chaotic-based discrete wavelet transform and Aquila optimisation tuned-artificial neural network approach for wind speed prediction," *Results Eng.*, vol. 14, no. December 2021, p. 100399, 2022, doi: 10.1016/j.rineng.2022.100399.
- [27] Z. G. Fang, S. Q. Yang, C. X. Lv, S. Y. An, and W. Wu, "Application of a data-driven XGBoost model for the prediction of COVID-19 in the USA: a time-series study," *BMJ Open*, vol. 12, no. 7, pp. 1–8, 2022, doi: 10.1136/bmjopen-2021-056685.
- [28] Y. Altork, "Comparative analysis of machine learning models for wind speed forecasting: Support vector machines, fine tree, and linear regression approaches," *Int. J. Thermofluids*, vol. 27, no. April, p. 101217, 2025, doi: 10.1016/j.ijft.2025.101217.
- [29] Y. C. Dewi and J. Purwadi, "Optimasi Parameter Support Vector Regression (SVR) Menggunakan Algoritma Grey Wolf Optimizer (GWO)," *J. Ilm. Mat.*, vol. 10, no. 1, pp. 25–33, Apr. 2025, doi: 10.26555/jim.v10i1.30867.