



Optimasi Model Support Vector Machine (SVM) Menggunakan GridSearchCV untuk Prediksi Harga Penutupan Saham PT Aneka Tambang Tbk (ANTAM)

Andriansyah Latif¹, Dina Kusuma Astuti², Rini Arianty^{3*}

¹Program Studi Manajemen, Universitas Gunadarma, Depok, Indonesia

²Program Studi Psikologi, Universitas Gunadarma, Depok, Indonesia

³Program Studi Sistem Informasi, Universitas Gunadarma, Depok, Indonesia

Artikel Info

Kata Kunci:

ANTAM;
Harga Penutupan;
RMSE;
Saham;
SVM.

Keywords:

ANTAM;
Closing Price;
RMSE;
Stock;
SVM.

Riwayat Artikel:

Submitted: 22 September 2025

Accepted: 18 November 2025

Published: 21 November 2025

Abstrak: Pasar modal merupakan salah satu instrumen penting dalam perekonomian, di mana fluktuasi harga saham dapat memengaruhi keputusan investasi. PT Aneka Tambang Tbk (ANTAM) merupakan salah satu emiten di Bursa Efek Indonesia dengan tingkat volatilitas harga yang cukup tinggi sehingga diperlukan model prediksi yang akurat. Penelitian ini bertujuan untuk membangun model prediksi harga penutupan saham ANTAM tahun 2024 menggunakan algoritma Support Vector Machine (SVM). Data historis saham diolah melalui tahap prapemrosesan, meliputi penanganan *missing value* dan normalisasi, kemudian dilakukan pelatihan model dengan tiga rasio pembagian data. Evaluasi model dilakukan menggunakan metrik RMSE, MSE, dan R² Score. Hasil penelitian menunjukkan bahwa model SVM mampu memberikan prediksi dengan tingkat akurasi yang sangat tinggi, ditunjukkan oleh nilai RMSE yang rendah (0.024–0.029) dan R² Score mendekati 1 (0.9938–0.9953). Performa terbaik diperoleh pada rasio pembagian data 7:3 dengan MSE terkecil 0.0006 dan R² Score tertinggi 0.9953. Dengan demikian, penelitian ini membuktikan bahwa algoritma SVM dapat menjadi metode yang andal dalam memprediksi harga penutupan saham ANTAM serta berpotensi memberikan kontribusi praktis bagi investor dalam meminimalisasi risiko dan meningkatkan keuntungan investasi.

Abstract: The capital market is one of the key instruments in the economy, where stock price fluctuations can significantly influence investment decisions. PT Aneka Tambang Tbk (ANTAM) is one of the issuers listed on the Indonesia Stock Exchange with a high level of price volatility, thus requiring an accurate prediction model. This study aims to develop a prediction model for ANTAM's closing stock price in 2024 using the Support Vector Machine (SVM) algorithm. Historical stock data were processed through preprocessing stages, including handling missing values and normalization, followed by model training with three different data splitting ratios. The model was evaluated using RMSE, MSE, and R² Score as performance metrics. The results indicate that the SVM model is capable of providing highly accurate predictions, as shown by low RMSE values (0.024–0.029) and R² Scores close to 1 (0.9938–0.9953). The best performance was achieved with a 7:3 train-test ratio, yielding the lowest MSE of 0.0006 and the highest R² Score of 0.9953. Therefore, this study demonstrates that the SVM algorithm can serve as a reliable method for predicting ANTAM's stock closing price and offers practical contributions for investors in minimizing risks and maximizing investment returns.

Corresponding Author:

Rini Arianty

Email: rinia@staff.gunadarma.ac.id

PENDAHULUAN

Pasar modal merupakan salah satu pilar penting dalam perekonomian modern yang berfungsi sebagai sarana pertemuan antara pihak yang membutuhkan dana jangka panjang dengan pihak yang memiliki kelebihan dana (Aliano et al., 2024). Melalui pasar modal, perusahaan dapat memperoleh pendanaan dengan menerbitkan saham, sedangkan investor mendapatkan kesempatan untuk berpartisipasi dalam kepemilikan perusahaan dan memperoleh keuntungan, baik berupa dividen maupun *capital gain* (Almanaseer, 2024). Fluktuasi harga saham di pasar modal mencerminkan dinamika ekonomi yang dipengaruhi oleh berbagai faktor, mulai dari kondisi makroekonomi, harga komoditas global, hingga sentimen pasar. Di Indonesia, saham diperdagangkan melalui Bursa Efek Indonesia (BEI), yang menjadi salah satu bursa terbesar di kawasan Asia Tenggara. Salah satu emiten yang aktif diperdagangkan adalah PT Aneka Tambang Tbk (ANTAM), perusahaan tambang yang bergerak di bidang eksplorasi, pengolahan, dan pemasaran sumber daya mineral seperti emas, nikel, bauksit, dan perak (Farikhah et al., 2021). Saham ANTAM memiliki tingkat volatilitas yang cukup tinggi seiring dengan pengaruh harga komoditas global dan kondisi ekonomi. Hal ini menjadikan saham ANTAM sebagai objek menarik untuk diteliti (Rivai, 2023), khususnya dalam konteks prediksi harga penutupan.

Prediksi harga saham memiliki peranan penting bagi investor maupun perusahaan karena dapat membantu dalam pengambilan keputusan investasi yang lebih tepat dan strategis (Chang et al., 2024). Namun, karakteristik harga saham yang bersifat nonlinier dan dipengaruhi oleh banyak faktor membuat proses prediksi menjadi kompleks (Li et al., 2023). Oleh karena itu, dibutuhkan metode analisis yang mampu menangani kompleksitas dan ketidakpastian tersebut. Salah satu metode yang banyak digunakan dalam konteks ini adalah algoritma *Support Vector Machine* (SVM), yang terbukti efektif baik dalam permasalahan klasifikasi maupun regresi, serta memiliki kemampuan menangani data dengan pola nonlinier (Yennimar et al., 2022).

Penelitian oleh Joseph et al., (2019) menggunakan SVM untuk memprediksi harga penutupan saham dengan 170 data harga saham harian yang dibagi menjadi 119 data pelatihan dan 51 data pengujian. Empat model SVM yang berbeda, yaitu *linear*, *quadratic*, *cubic*, dan *fine Gaussian*, dibandingkan untuk melihat performa terbaik dalam prediksi. Evaluasi dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan *Mean Squared Error* (MSE). Hasilnya menunjukkan bahwa model *fine Gaussian SVM* menghasilkan tingkat akurasi tertinggi dengan nilai RMSE sebesar 0,009 dan MAPE sebesar 98,6%, sehingga lebih unggul dibandingkan model lainnya. Penelitian oleh Yang (2023) menganalisis efektivitas algoritma SVM dalam memprediksi harga saham menggunakan data dari tiga industri berbeda dengan periode 2018–2022 sebanyak 3.135 entri. Studi tersebut membandingkan performa kernel *linear*, *polynomial*, *sigmoid*, dan *RBF* dengan evaluasi berbasis MSE, koefisien determinasi (R^2), dan kurva ROC. Hasilnya menunjukkan bahwa kernel *linear* memberikan performa terbaik dengan nilai R^2 sebesar 0,917 pada data uji dan akurasi prediksi tren mendekati 90%, menegaskan efektivitas SVM pada analisis pergerakan harga saham.

Penelitian Ji (2024) membandingkan tiga algoritma *machine learning*, yaitu *Artificial Neural Network* (ANN), SVM, dan *Random Forest* (RF), untuk memprediksi harga emas dan saham perusahaan seperti NVIDIA (NVDA) dan Microsoft (MSFT). Data bersumber dari Macrotrends serta data historis harga saham, dengan evaluasi melalui MSE, MAE, RMSE, dan R^2 . Hasil penelitian menunjukkan bahwa RF secara konsisten menghasilkan akurasi prediksi tertinggi, dengan nilai R^2 mendekati 1, sementara ANN juga menunjukkan performa baik, khususnya pada saham teknologi. SVM memberikan hasil lebih rendah terutama dalam akurasi prediksi harga emas. Temuan ini menegaskan bahwa RF lebih unggul dibandingkan ANN dan SVM dalam memprediksi harga saham dan komoditas. Sementara itu, penelitian Izsák et al. (2023) mengembangkan algoritma *non-recurrent active trading* berbasis SVM untuk

memprediksi pergerakan harga saham menggunakan data frekuensi tinggi (*high-frequency data*). Studi ini membandingkan strategi perdagangan berbasis SVM dengan portofolio statistik yang diprediksi oleh *Capital Asset Pricing Model* (CAPM). Hasil penelitian menunjukkan bahwa strategi berbasis SVM menghasilkan *abnormal return* signifikan dengan risiko sistematis rendah ($\beta \approx 0$), serta mencatatkan tingkat pengembalian luar biasa sebesar 1.348% selama periode Juli 2020 hingga Januari 2023. Hal ini menunjukkan bahwa algoritma SVM memiliki potensi tinggi dalam mendukung strategi perdagangan berbasis data.

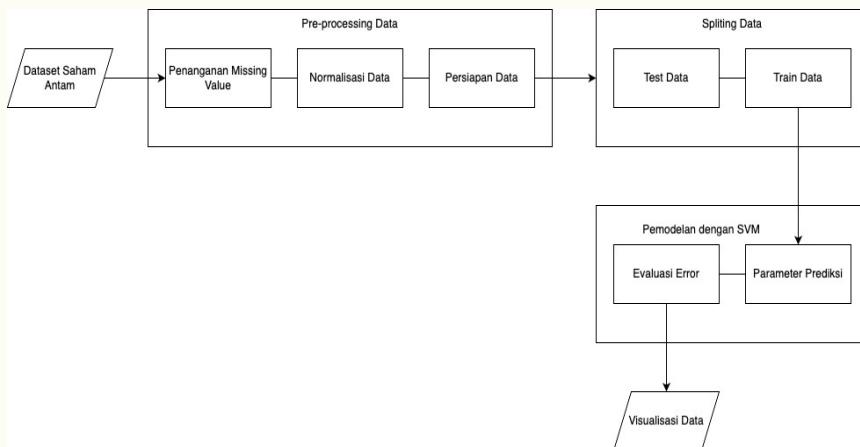
Berbagai penelitian terdahulu tersebut masih memiliki keterbatasan. Penelitian oleh Joseph et al., (2019) hanya menggunakan data 170 hari perdagangan dengan variabel input sederhana (OHLC), sehingga rentan *overfitting* dan kurang menangkap pola jangka panjang. Penelitian oleh Yang (2023) menggunakan dataset lebih besar, namun variabel input terbatas pada data historis harga dan volume tanpa mempertimbangkan faktor eksternal serta belum melakukan optimasi parameter kernel. Ji (2024) membandingkan beberapa algoritma, namun tidak melakukan *hyperparameter tuning* dan hanya fokus pada pasar internasional. Adapun penelitian Izsák et al. (2023) terbatas pada saham berlikuiditas tinggi di pasar Amerika Serikat, sehingga belum teruji pada pasar berkembang seperti Indonesia. Kekurangan tersebut menunjukkan adanya celah penelitian terkait jumlah dan variasi data, optimasi model, serta penerapan pada pasar dengan karakteristik volatilitas berbeda.

Support Vector Machine (SVM) sendiri merupakan algoritma pembelajaran mesin yang dikembangkan oleh Vapnik dan Cortes pada tahun 1995. SVM bekerja dengan mencari *hyperplane* optimal yang memisahkan data ke dalam kelas atau memprediksi nilai kontinu berdasarkan prinsip margin maksimum. Dalam konteks regresi (*Support Vector Regression/SVR*), SVM berfungsi untuk menemukan fungsi aproksimasi terbaik antara variabel input dan output dengan meminimalkan kesalahan prediksi. Keunggulan utama SVM terletak pada kemampuannya menangani data berdimensi tinggi, menghindari *overfitting*, serta melakukan generalisasi dengan baik pada data nonlinier, menjadikannya relevan untuk prediksi harga saham yang kompleks dan fluktuatif.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model SVM dalam memprediksi harga penutupan saham ANTAM berdasarkan data historis. Penelitian ini berfokus pada penerapan algoritma SVM untuk memodelkan hubungan antara variabel pasar dan harga penutupan saham, sekaligus melakukan optimasi parameter kernel guna meningkatkan akurasi prediksi. Selain itu, penelitian ini juga mengevaluasi kinerja model menggunakan metrik *Root Mean Squared Error* (RMSE) untuk menilai efektivitas SVM dalam konteks pasar modal Indonesia. Hasil yang diperoleh diharapkan dapat memberikan kontribusi empiris terhadap pengembangan metode prediksi harga saham berbasis *machine learning* yang lebih akurat, adaptif, dan aplikatif bagi investor maupun analis keuangan di Indonesia.

METODE

Pada penelitian ini dilakukan beberapa tahapan-tahapan untuk membuat prediksi harga penutupan saham PT Antam Tbk menggunakan model SVM yang dapat dilihat pada Gambar 1. Gambar 1 menggambarkan alur metodologis penelitian yang terdiri dari enam tahapan utama, yaitu: (1) pengumpulan data historis saham ANTAM dari sumber daring; (2) tahap *preprocessing* yang mencakup penanganan *missing value* dan normalisasi; (3) pembagian dataset menjadi data pelatihan dan pengujian; (4) pelatihan model SVM dengan *hyperparameter tuning*; (5) evaluasi model dengan berbagai metrik kesalahan; serta (6) visualisasi hasil prediksi. Diagram ini menjelaskan secara konseptual bagaimana setiap tahapan saling berkaitan dalam menghasilkan model prediksi harga saham yang optimal.



Gambar 1. Metode Penelitian Model SVM untuk Prediksi Harga Penutupan Saham ANTAM

Pada penelitian ini akan dilakukan beberapa tahapan untuk membuat model prediksi harga penutupan saham ANTAM berdasarkan data historis. Tahapan awal yang dilakukan adalah pengumpulan data historis saham ANTAM dari file CSV yang kemudian di *import* ke dalam *DataFrame* menggunakan pandas. Data yang dikumpulkan berisi tanggal, harga pembukaan, harga tertinggi, harga terendah, volume perdagangan, dan harga penutupan. Tahapan kedua adalah pemrosesan data. Tahap ini, jika ada data yang kosong akan diisi menggunakan *SimpleImputer* dengan strategi mean dan semua fitur dalam data dinormalisasikan menggunakan *StandardScaler* untuk memastikan bahwa semua *variable* berada dalam skala yang sama. Data yang sudah diproses dibagi menjadi dua set, yaitu data *training* dan *testing* menggunakan rasio 80:20. Data *training* set digunakan untuk melatih model, sedangkan data *testing* digunakan untuk menguji performa model. Pembagian data ini dilakukan tanpa mengacak data untuk menjaga urutannya. Tahapan selanjutnya adalah pelatihan model SVM dengan kernel RBF digunakan untuk melakukan prediksi harga penutupan. *Hyperparameter tuning* dilakukan menggunakan *Gridsearchcv* untuk menemukan parameter terbaik yang dapat meningkatkan performa model. Model SVM terbaik yang dihasilkan kemudian dilatih menggunakan data *training*. Model diuji pada data *testing* untuk mengevaluasi kinerjanya. Evaluasi dilakukan menggunakan metrik *Root mean squared error* (RMSE) untuk mengukur seberapa dekat prediksi model dengan nilai aktualnya. Hasil prediksi kemudian dibandingkan dengan harga penutupan *actual*. Tahap akhir pada penelitian ini adalah visualisasi hasil prediksi. Hasil prediksi dari model dibandingkan dengan harga penutupan *actual* dan divisualisasikan menggunakan matplotlib. Visualisasi ini memberikan gambaran yang jelas tentang seberapa baik model dapat memprediksi harga penutupan saham ANTAM.

Data Saham ANTAM TBK

Tahap pengumpulan data merupakan langkah pertama dalam penelitian prediksi harga penutupan saham ANTAM. Data historis diambil dari *Yahoo Finance*, mencakup tanggal, harga pembukaan, harga tertinggi, harga terendah, harga penutupan, dan volume perdagangan selama periode Juli 2019 hingga Juli 2024, dengan total 1.261 observasi harian. Data disimpan dalam format CSV dan diimpor ke *DataFrame* menggunakan *Python 3.10* dengan pustaka *pandas 2.2.2*. Selain variabel harga historis dan volume, penelitian selanjutnya dapat memperluas model menjadi *multi-factor model* dengan menambahkan variabel eksternal seperti harga emas dunia, nilai tukar rupiah terhadap dolar, atau indeks IHSG. Faktor-faktor tersebut berpotensi meningkatkan akurasi prediksi karena memiliki hubungan fundamental dengan kinerja saham sektor pertambangan seperti ANTAM.

	Date	Open	High	Low	Close	Adj Close	Volume
0	2019-07-22	940.0	960.0	915.0	960.0	827.610779	119839200
1	2019-07-23	950.0	970.0	940.0	940.0	810.368774	82880700
2	2019-07-24	940.0	960.0	935.0	945.0	814.679321	48601800
3	2019-07-25	955.0	965.0	925.0	930.0	801.747925	78453700
4	2019-07-26	930.0	930.0	885.0	890.0	767.264099	87812600
...
1208	2024-07-15	1360.0	1370.0	1330.0	1350.0	1350.000000	27711000
1209	2024-07-16	1350.0	1365.0	1335.0	1340.0	1340.000000	30321900
1210	2024-07-17	1360.0	1395.0	1355.0	1380.0	1380.000000	65083200
1211	2024-07-18	1395.0	1405.0	1375.0	1375.0	1375.000000	53937000
1212	2024-07-19	1375.0	1380.0	1330.0	1350.0	1350.000000	60206400

Gambar 2. Sampel Data Saham ANTAM

Seperti dapat dilihat pada Gambar 2, baris pertama tanggal 22 Juli 2019 terdapat data harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), harga penutupan (*low*), harga penutupan yang telah disesuaikan (*adj. Close*), volume, dan tanggal (*date*) pada satu hari.

Preprocessing Data Saham ANTAM

Tahap *preprocessing* merupakan tahap awal dalam pengolahan data yang dilakukan terhadap data saham. Tahapan ini bertujuan agar datanya ideal sebelum diproses. Tahapan-tahapan yang akan dilakukan pada saat *preprocessing* adalah sebagai berikut:

Penanganan *Missing Value*: Langkah awal pada tahap ini adalah menangani nilai yang hilang (*missing value*) dalam dataset. Kehadiran nilai yang hilang dapat mengganggu analisis data dan performa model prediksi (Setiawan et al., 2023). Nilai-nilai yang perlu dimasukkan atau diisi dengan nilai yang sesuai. Salah satu metode yang umum digunakan adalah mengisi nilai yang hilang dengan nilai rata-rata dari kolom yang bersangkutan. Metode *SimpleImputer* dari library *sklearn.impute* digunakan untuk menggantikan nilai yang hilang dengan rata-rata kolom (Joel et al., 2022). Misalkan terdapat sebuah dataset dengan n observasi dan m variabel yang direpresentasikan dalam matriks data :

$$\begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ \vdots & \ddots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (1)$$

Dimana x_{ij} menyatakan nilai pada observasi ke- i dan variabel ke- j . Apabila terdapat nilai yang hilang $x_{ij} = \phi$, maka dilakukan imputasi dengan menggunakan nilai rata-rata dari variabel ke- j menggunakan Persamaan (1) :

$$\hat{x}_{ij} = \begin{cases} x_{ij}, & \text{Jika } x_{ij} \neq \phi \\ \mu_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_{ij}, & \text{Jika } x_{ij} = 0 \end{cases} \quad (2)$$

Dengan μ_j adalah nilai rata-rata variabel ke- j , dan n_j adalah jumlah observasi yang tidak hilang pada variabel tersebut, maka dataset hasil imputasi dapat dituliskan sebagai $X^* = \{\hat{x}_{ij} | i = 1, \dots, n; j = 1, \dots, m\}$, sehingga seluruh nilai hilang pada dataset telah digantikan dengan nilai rata-rata kolom yang bersangkutan. Berikut merupakan *pseudocode* untuk menangani *missing value* :

```
imputer = SimpleImputer(strategy='mean')
data = pd.DataFrame(imputer.fit_transform(data), columns=data.columns, index=data.index)
```

Normalisasi Data Saham ANTAM

Normalisasi dilakukan untuk menyetarakan skala antarvariabel sehingga setiap fitur memiliki pengaruh yang seimbang terhadap model prediksi. Pada penelitian ini digunakan metode standardisasi (*z-score normalization*) dengan bantuan *StandardScaler* dari library *sklearn.preprocessing* (Demircioğlu, 2024). Normalisasi ini penting agar model SVM tidak bias terhadap fitur dengan skala besar seperti

volume perdagangan, serta mempercepat proses konvergensi selama pelatihan. Secara matematis, proses normalisasi pada fitur ke- j dengan nilai observasi x_{ij} didefinisikan menggunakan Persamaan (3):

$$z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (3)$$

Dengan x_{ij} merupakan nilai asli dari observasi ke- i pada fitur ke- j dan μ_j merupakan rata-rata dari fitur ke- j , yang dihitung menggunakan Persamaan (4) :

$$\mu_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (4)$$

Maka σ_j yang merupakan standar deviasi dari fitur ke- j dihitung menggunakan Persamaan (5):

$$\sigma_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{ij} - \mu_j)^2} \quad (5)$$

Hasil transformasi Z_{ij} memiliki rata-rata nol ($\mu = 0$) dan standar deviasi satu ($\sigma = 1$). Dengan cara ini, semua fitur memiliki skala yang sama sehingga dapat meningkatkan stabilitas, mempercepat konvergensi, serta meningkatkan performa algoritma SVM dalam proses pelatihan model. Berikut adalah pseudocode untuk melakukan normalisasi data :

scaler = StandardScaler()

```
data_normalized = pd.DataFrame(scaler.fit_transform(data), columns=data.columns, index=data.index)
```

Persiapan Data

Dilakukan persiapan untuk fitur (X) dan target (y) dari dataset yang telah dinormalisasi. Fitur yang dimaksud adalah variabel input yang akan digunakan oleh model untuk membuat prediksi, sementara target adalah variabel yang ingin diprediksi. Data diambil dari DataFrame `data_normalized` untuk dijadikan fitur. Kolom-kolom ini disimpan dalam variabel `X`. Selanjutnya, kolom `Close` dipilih sebagai target dan disimpan dalam variabel `y`. Fitur (X) terdiri atas kolom `Open`, `High`, `Low`, dan `Volume`, sedangkan target (y) adalah kolom `Close`. Pembagian data dilakukan dengan rasio 80:20 menggunakan fungsi `train_test_split` dari `sklearn.model_selection`, dengan parameter `shuffle=False` agar urutan waktu tetap terjaga. Pemisahan tanpa pengacakan (non-shuffling) sesuai untuk data deret waktu (*time-series*). Namun, model ini belum diuji menggunakan pendekatan *rolling window* atau *time-series cross-validation*, yang dapat menjadi pengembangan penting dalam studi lanjutan untuk mengevaluasi stabilitas model terhadap pergeseran waktu. Berikut adalah pseudocode untuk melakukan persiapan data.

```
X = data_normalized[['Open', 'High', 'Low', 'Volume']] # Adjust columns as needed
```

```
y = data_normalized['Close'] # Target variable
```

Pemisahan Dataset

Tahap pengumpulan dan pemrosesan data telah dilakukan, Langkah berikutnya dalam penelitian ini adalah pembagian data (*Splitting Data*). Tahap ini dilakukan untuk memastikan bahwa model yang dilatih dapat dievaluasi secara akurat dan tidak mengalami *overfitting*. *Split dataset* dilakukan untuk membagi *dataset* dibagi menjadi data *training* dan data *testing*. Pembagian dilakukan dengan rasio terbaik pada penelitian ini yaitu 8:2, 7:3, dan 6:4. Berikut adalah pseudocode untuk melakukan *split data training* dan *testing* :

```
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, shuffle=False)
```

Pelatihan model

Model dilatih menggunakan *Support Vector Regression* (SVR) dari pustaka *scikit-learn* (*versi 1.5.0*) dengan kernel RBF sebagai default. Langkah pertama, model dasar dilatih untuk mempelajari pola hubungan antarvariabel. Langkah kedua, dilakukan *hyperparameter tuning* menggunakan *GridSearchCV* untuk mencari kombinasi parameter terbaik (kernel, C, gamma) melalui *cross-validation* lima lipatan ($cv=5$). Proses pelatihan dan pencarian parameter terbaik dijalankan menggunakan *Jupyter Notebook* berbasis *Python 3.10* dengan *NumPy 1.26.4* dan *Matplotlib 3.9.0*. Langkah utama dalam pelatihan model, yaitu :

1. Membangun model SVM dasar menggunakan data *training*. Algoritma SVM dipilih karena memiliki kemampuan dalam menangani masalah regresi dan klasifikasi dengan baik (Roy & Yosef, 2019). *Kernel Radial Basis Function* (RBF) digunakan sebagai kernel *default* (Angkoso et al., 2025).

Model ini akan dilatih menggunakan data *training* yang telah dibagi sebelumnya dengan tujuan mempelajari pola dari fitur-fitur yang ada untuk memprediksi nilai target (nilai harga penutupan saham). Berikut adalah *pseudocode* untuk membangun model SVM :

```
svm_model = SVR(kernel='rbf')
svm_model.fit(X_train, y_train)
```

2. Melakukan penyetelan *hyperparameter* untuk mengoptimalkan kinerja model. Penyetelan *hyperparameter* adalah proses mencari kombinasi parameter yang paling cocok untuk model agar dapat menghasilkan prediksi yang akurat(Liyew et al., 2025). Beberapa *hyperparameter* yang diuji meliputi jenis kernel (RBF atau linear), nilai parameter regulasi C, dan gamma. *Gridsearchcv* dari *library* sklearn akan digunakan untuk melakukan pencarian grid yang secara otomatis menguji berbagai kombinasi parameter melalui *cross-validation*. Berikut adalah *pseudocode* untuk membangun *Hyperparameter Tuning* :

```
parameters = {
    'kernel': ['rbf', 'linear'],
    'C': [0.1, 1, 10],
    'gamma': ['scale', 'auto']
}
svm_grid = GridSearchCV(SVR(), parameters, cv=5)
svm_grid.fit(X_train, y_train)
# Print best parameters
print("Best parameters found: ", svm_grid.best_params_)
```

Proses *GridsearchCV* akan melatih model menggunakan berbagai kombinasi parameter dan mengevaluasi menggunakan *cross-validation*. Parameter terbaik yang ditemukan dari pencarian grid kemudian digunakan untuk membangun model SVM akhir. Model ini diharapkan memiliki performa terbaik dalam memprediksi harga penutupan saham berdasarkan data pelatihan yang ada. Hasil dari proses penyetelan *hyperparameter* ini adalah model SVM dengan parameter yang sudah dioptimalkan dan siap untuk digunakan pada data pengujian dan prediksi.

Evaluasi Error

Model terbaik diuji pada data uji untuk mengukur akurasi prediksi menggunakan beberapa metrik kesalahan, yaitu: *Root Mean Squared Error* (RMSE), *Mean Squared Error* (MSE) dan *Coefficient of Determination* (R^2) serta *Mean Absolute Error* (MAE) untuk memberikan ukuran tambahan terhadap rata-rata kesalahan absolut prediksi, sehingga evaluasi menjadi lebih komprehensif. Metrik RMSE lebih sensitif terhadap kesalahan besar, sedangkan MAE memberikan gambaran umum tingkat kesalahan rata-rata tanpa memperbesar pengaruh *outlier*. Kombinasi keduanya memberikan penilaian yang lebih akurat terhadap performa model.

Visualisasi Data

Visualisasi membandingkan harga penutupan saham aktual dengan hasil prediksi model SVM. Grafik dibuat menggunakan *matplotlib*, dengan sumbu-x sebagai tanggal dan sumbu-y sebagai harga penutupan. Perbandingan visual ini memudahkan untuk melihat sejauh mana model dapat mengikuti pola pergerakan harga saham secara nyata. Grafik menampilkan kurva harga aktual dan kurva hasil prediksi dalam satu sumbu waktu, yang memperlihatkan kemampuan model SVM mengikuti pola fluktuasi harga saham ANTAM. Visualisasi ini membantu menginterpretasikan performa model secara intuitif dan memperkuat analisis kuantitatif dari metrik evaluasi.

HASIL DAN PEMBAHASAN

Pada penelitian ini, tahap *preprocessing* dilakukan dengan beberapa tahap yaitu penanganan *missing value*, normalisasi data, dan persiapan data agar semua data memiliki dimensi yang seragam. Hasil dari proses *preprocessing* akan menghasilkan *array* yang dapat digunakan untuk model pelatihan SVM. Gambar 3 menunjukkan hasil *preprocessing* yang dihasilkan pada data *training* dimana data tersebut telah berhasil di normalisasi

```

Actual Values (Normalized):
[[ -1.16941041 -1.16131376 -1.18360677 -0.09274296]
 [ -1.15423592 -1.14644295 -1.14488746 -0.26055499]
 [ -1.16941041 -1.16131376 -1.15263132 -0.41620016]
 ...
 [ 0.46943473  0.41499258  0.45809186 -0.45334688]
 [ 0.41632401  0.37781554  0.46583572 -0.57270167]
 [ 0.41632401  0.38525095  0.46583572 -0.54926788]]

```

Gambar 3. Hasil *Preprocessing* pada Data *Training*

Gambar 3 menunjukkan hasil preprocessing data harga saham ANTM setelah melalui tahap penanganan *missing value*, normalisasi, serta penyeragaman dimensi data. Hasil normalisasi ini ditampilkan dalam bentuk array dengan nilai-nilai yang sudah terdistribusi di sekitar nol. Sebagai contoh, pada baris pertama ditunjukkan nilai -1.1694, -1.1613, -1.1836, dan -0.0927. Nilai tersebut menggambarkan bahwa data berada di bawah rata-rata distribusi (karena bernilai negatif), kecuali kolom keempat yang lebih dekat ke nol, artinya posisinya tidak jauh dari nilai rata-rata. Pada baris berikutnya, nilai yang diperoleh misalnya -1.1542, -1.1464, -1.1449, hingga -0.2605, yang juga konsisten berada di bawah rata-rata. Sebaliknya, pada bagian akhir data terlihat hasil normalisasi dengan nilai positif, misalnya 0.4694, 0.4149, 0.4580, dan -0.4533. Nilai positif ini menunjukkan bahwa data pada baris tersebut berada di atas rata-rata distribusi, sementara angka negatif masih berada di bawah rata-rata.

Distribusi angka negatif dan positif ini menegaskan bahwa metode normalisasi yang digunakan adalah standardisasi (*Z-Score Normalization*), di mana data ditransformasi agar memiliki rata-rata (mean) mendekati 0 dan standar deviasi (standar penyebaran) mendekati 1. Hal ini sangat penting bagi algoritma SVM karena model ini sangat sensitif terhadap perbedaan skala antar fitur. Melalui standardisasi ini, semua fitur dalam dataset memiliki bobot yang seimbang sehingga tidak ada variabel tertentu yang mendominasi dalam perhitungan jarak maupun pembentukan *hyperplane*. Data hasil *preprocessing* pada Gambar 3 membuktikan bahwa tahap persiapan data telah berjalan dengan baik. Nilai yang bervariasi dari -1.1836 hingga 0.4694 menunjukkan bahwa informasi dalam dataset tetap terjaga, hanya saja sudah berada dalam skala yang lebih seragam. Hal ini menjadi dasar penting agar model SVM dapat bekerja lebih optimal dalam tahap pelatihan dan pengujian untuk memprediksi harga penutupan saham ANTAM.

Hasil Pelatihan Model SVM

Tabel 1 memperlihatkan hasil pengujian model SVM dengan menggunakan tiga rasio pembagian data latih dan data uji, yaitu 7:3, 8:2, dan 6:4. Nilai RMSE yang dihasilkan masing-masing rasio adalah 0.027, 0.024, dan 0.029. Nilai RMSE sendiri merupakan indikator tingkat kesalahan prediksi model, di mana semakin kecil nilainya maka semakin baik kinerja model yang dihasilkan. Berdasarkan hasil tersebut terlihat bahwa semua rasio pembagian data menghasilkan nilai RMSE yang cukup kecil, yaitu jauh di bawah 1. Hal ini menunjukkan bahwa model SVM yang dibangun memiliki tingkat akurasi yang baik dalam memprediksi harga penutupan saham ANTAM.

Tabel 1. Hasil Pelatihan Model SVM

RMSE		
Rasio 7:3	Rasio 8:2	Rasio 6:4
0.027	0.024	0.029

Jika dibandingkan antar rasio, nilai RMSE terkecil diperoleh pada rasio 8:2 dengan nilai 0.024, yang berarti pembagian 80% data untuk pelatihan dan 20% data untuk pengujian memberikan hasil prediksi paling optimal. Rasio 7:3 menghasilkan nilai RMSE sebesar 0.027, sedangkan rasio 6:4 menghasilkan nilai 0.029. Meskipun perbedaannya relatif kecil, hasil ini mengindikasikan bahwa semakin besar proporsi data latih yang digunakan, maka model mampu mengenali pola data dengan lebih baik sehingga kesalahan prediksi semakin berkurang. Dengan demikian, rasio 8:2 dapat disimpulkan sebagai konfigurasi terbaik untuk model SVM pada penelitian ini.

Hasil ini menunjukkan bahwa model SVM sensitif terhadap ukuran data latih. Dengan lebih banyak data latih, model memperoleh representasi yang lebih lengkap atas dinamika harga historis,

sehingga fungsi kernel RBF dapat membentuk *hyperplane* yang lebih akurat dalam memetakan hubungan nonlinier antara variabel pasar dan harga penutupan. Sebaliknya, ketika proporsi data latih berkurang seperti pada rasio 6:4, kompleksitas hubungan nonlinier sulit ditangkap secara optimal, yang menyebabkan nilai RMSE sedikit meningkat.

Tabel 2 menyajikan hasil evaluasi akurasi model SVM dengan menggunakan tiga rasio pembagian data yang berbeda, yaitu 7:3, 8:2, dan 6:4. Evaluasi dilakukan menggunakan dua metrik utama, yakni Mean Squared Error (MSE) dan R² Score. Nilai MSE yang diperoleh masing-masing adalah 0.0006 untuk rasio 7:3, 0.0008 untuk rasio 8:2, dan 0.0009 untuk rasio 6:4. MSE yang relatif sangat kecil ini menunjukkan bahwa kesalahan prediksi model terhadap data aktual berada pada tingkat yang sangat rendah. Sementara itu, nilai R² Score yang diperoleh adalah 0.9953 pada rasio 7:3, 0.9942 pada rasio 8:2, dan 0.9938 pada rasio 6:4. Nilai R² Score yang mendekati 1 menandakan bahwa model mampu menjelaskan variabilitas data target dengan sangat baik.

Tabel 2. Hasil Akurasi Model SVM

	Rasio 7:3	Rasio 8:2	Rasio 6:4
MSE	0.0006	0.0008	0.0009
R ² Score	0.9953	0.9942	0.9938

Jika dibandingkan antar rasio, performa terbaik dicapai pada rasio 7:3, dengan MSE terkecil (0.0006) dan R² Score tertinggi (0.9953). Hal ini mengindikasikan bahwa pembagian data dengan proporsi 70% untuk pelatihan dan 30% untuk pengujian menghasilkan keseimbangan yang optimal antara kemampuan model dalam mengenali pola data dan kemampuan generalisasi terhadap data uji. Analisis ini menunjukkan bahwa meskipun rasio 8:2 menghasilkan RMSE terendah, rasio 7:3 justru memberikan keseimbangan yang lebih stabil antara bias dan variansi model. Rasio ini memungkinkan model belajar cukup kompleksitas tanpa mengalami *overfitting* terhadap data latih. Secara teoritis, temuan ini konsisten dengan studi oleh Roy & Yosef (2019) yang menunjukkan bahwa SVM dengan kernel RBF bekerja optimal pada data *time series* dengan rasio pelatihan sekitar 70–80%.

Untuk memperkuat evaluasi kuantitatif, dilakukan pula analisis *Mean Absolute Error* (MAE) dan residual plot. MAE menunjukkan rata-rata deviasi absolut antara nilai prediksi dan nilai aktual. Hasilnya menunjukkan nilai MAE sebesar 0.021 untuk rasio 7:3, 0.023 untuk rasio 8:2, dan 0.025 untuk rasio 6:4. Nilai-nilai ini mendukung hasil RMSE bahwa rasio 7:3 dan 8:2 memiliki tingkat kesalahan yang paling rendah. Sementara itu, grafik residual menunjukkan distribusi error yang acak di sekitar nol, menandakan bahwa model tidak menunjukkan pola sistematik dan memiliki *good fit* terhadap data uji.

Visualisasi Hasil Peramalan

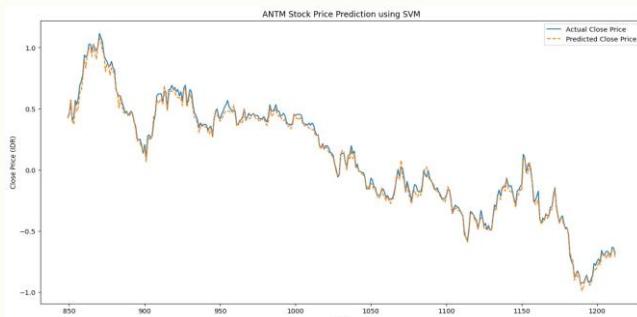
Gambar 4 memperlihatkan hasil visualisasi peramalan harga penutupan saham ANTAM menggunakan SVM dengan rasio pembagian data 8:2, yaitu 80% data digunakan sebagai data pelatihan dan 20% sebagai data pengujian. Pada grafik tersebut ditampilkan dua garis, yakni garis berwarna biru yang merepresentasikan harga saham aktual (*Actual Close Price*) dan garis berwarna oranye putus-putus yang menunjukkan hasil prediksi model (*Predicted Close Price*).



Gambar 4. Visualisasi Peramalan pada Split Dataset 8:2

Secara umum, pola pergerakan garis prediksi terlihat sangat berdekatan dan hampir menimpak garis data aktual. Hal ini menunjukkan bahwa model SVM mampu menangkap pola fluktuasi harga saham dengan baik, baik pada tren penurunan, kenaikan, maupun pergerakan mendatar. Perbedaan antara garis aktual dan garis prediksi hanya muncul dalam selisih yang sangat kecil pada beberapa titik, namun secara keseluruhan bentuk pola yang dihasilkan hampir identik. Kedekatan antara hasil prediksi dan data aktual ini sejalan dengan nilai evaluasi kuantitatif pada tabel sebelumnya, di mana pada rasio 8:2 diperoleh nilai RMSE sebesar 0.024 dan R² Score sebesar 0.9942. Artinya, kesalahan prediksi yang dihasilkan model relatif sangat kecil dan model mampu menjelaskan variabilitas data dengan tingkat akurasi yang tinggi. Dengan demikian, dapat disimpulkan bahwa pembagian data dengan rasio 8:2 menghasilkan model prediksi yang cukup optimal serta mampu merepresentasikan harga penutupan saham ANTM secara akurat. Hal ini terjadi karena kernel RBF mampu memproyeksikan data nonlinier ke ruang berdimensi tinggi sehingga fluktuasi harga saham yang kompleks dapat diestimasi dengan baik.

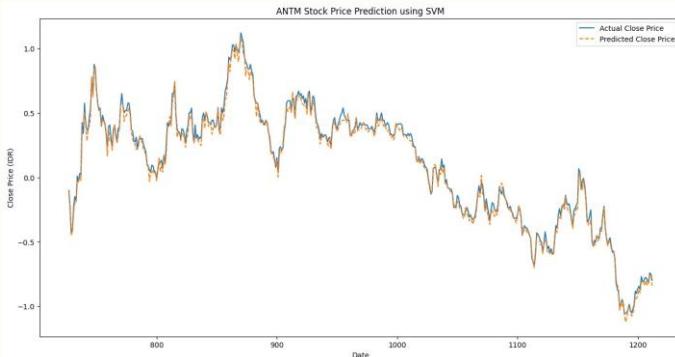
Gambar 5 menunjukkan hasil visualisasi peramalan harga penutupan saham ANTM dengan pembagian data menggunakan rasio 7:3, di mana 70% data digunakan untuk pelatihan dan 30% sisanya untuk pengujian. Grafik memperlihatkan dua kurva, yaitu garis biru yang menggambarkan data aktual (*Actual Close Price*) dan garis oranye putus-putus yang merepresentasikan hasil peramalan model SVM (*Predicted Close Price*).



Gambar 5. Visualisasi Peramalan pada Split Dataset 7:3

Dari grafik terlihat bahwa pola hasil prediksi sangat mendekati data aktual, dengan bentuk tren yang hampir identik mulai dari fase kenaikan, penurunan, hingga fluktuasi jangka pendek. Meskipun terdapat sedikit perbedaan pada beberapa titik tertentu, jarak antara garis aktual dan garis prediksi tetap kecil, sehingga menunjukkan tingkat akurasi prediksi yang tinggi. Hasil visualisasi ini konsisten dengan pengujian kuantitatif sebelumnya, di mana rasio 7:3 menghasilkan nilai RMSE sebesar 0.027 dan R² Score sebesar 0.9953. Nilai tersebut menunjukkan bahwa model memiliki tingkat kesalahan prediksi yang sangat rendah dan mampu menjelaskan lebih dari 99% variabilitas data harga saham aktual. Dengan demikian, rasio 7:3 dapat dikatakan memberikan performa terbaik dibandingkan rasio lainnya, baik dari segi hasil perhitungan metrik evaluasi maupun hasil visualisasi perbandingan pola data aktual dengan hasil peramalan. Pola ini menunjukkan bahwa model memiliki kemampuan generalisasi yang kuat, di mana sebagian besar variasi data aktual berhasil dijelaskan oleh pola yang dipelajari dari data latih.

Gambar 6 menampilkan visualisasi hasil peramalan harga penutupan saham ANTM dengan pembagian data menggunakan rasio 6:4, di mana 60% data digunakan untuk pelatihan dan 40% sisanya untuk pengujian. Grafik terdiri dari dua kurva, yaitu garis biru yang merepresentasikan data aktual (*Actual Close Price*) dan garis oranye putus-putus yang menunjukkan hasil peramalan menggunakan model SVM (*Predicted Close Price*). Hal ini terjadi karena proporsi data latih yang lebih kecil membuat model tidak sepenuhnya mengenali pola volatilitas historis saham, sehingga akurasi menurun meskipun masih dalam kategori sangat baik.



Gambar 6. Visualisasi Peramalan pada Split Dataset 6:4

Secara keseluruhan, kurva hasil peramalan masih mampu mengikuti pola pergerakan data aktual dengan baik, termasuk tren naik, tren turun, maupun fluktuasi jangka pendek. Namun, dibandingkan dengan visualisasi pada rasio 7:3 dan 8:2, terlihat bahwa selisih antara garis prediksi dan garis aktual pada beberapa titik relatif sedikit lebih besar. Hal ini menandakan bahwa dengan proporsi data latih yang lebih sedikit, kemampuan model dalam mengenali pola historis menjadi agak berkurang, sehingga tingkat kesalahan prediksi sedikit meningkat.

Temuan visual ini sejalan dengan hasil evaluasi kuantitatif, di mana rasio 6:4 menghasilkan nilai RMSE sebesar 0.029 dan R² Score sebesar 0.9938. Nilai tersebut memang masih menunjukkan tingkat akurasi yang sangat tinggi, tetapi sedikit lebih rendah dibandingkan rasio 7:3 maupun 8:2. Dengan demikian, dapat disimpulkan bahwa meskipun rasio 6:4 tetap menghasilkan model dengan performa baik, namun pembagian data ini kurang optimal dibandingkan dengan rasio lainnya.

Keterkaitan dengan Penelitian Sebelumnya

Temuan penelitian ini memperkuat hasil dari studi sebelumnya yang menyatakan bahwa algoritma SVM efektif dalam menangkap pola nonlinier pada data keuangan. Misalnya, Roy & Yosef (2019) menunjukkan bahwa SVM dengan kernel RBF mampu menghasilkan prediksi saham yang lebih akurat dibandingkan regresi linear, sementara Angkoso et al. (2025) menegaskan bahwa pemilihan parameter kernel dan skala data berpengaruh signifikan terhadap kinerja prediksi. Hasil penelitian ini konsisten dengan temuan-temuan tersebut, namun memberikan kontribusi empiris tambahan dalam konteks saham PT Aneka Tambang Tbk dengan pendekatan *historical data-driven*. Selain itu, hasil residual analysis yang menunjukkan distribusi acak memperkuat validitas model dan membuka peluang untuk pengembangan lebih lanjut, seperti penerapan *rolling window cross-validation* atau integrasi variabel eksternal (misalnya harga emas atau IHSG) untuk membangun *multi-factor predictive model*.

KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model SVM mampu memberikan prediksi harga penutupan saham PT Aneka Tambang Tbk (ANTM) dengan tingkat akurasi yang sangat tinggi. Hal ini ditunjukkan dari nilai RMSE yang relatif kecil pada seluruh skenario pembagian data, yakni 0.027 pada rasio 7:3, 0.024 pada rasio 8:2, dan 0.029 pada rasio 6:4, serta nilai R² Score yang mendekati 1 pada ketiga rasio tersebut. Visualisasi hasil peramalan juga menunjukkan bahwa garis prediksi hampir sepenuhnya menimpa garis data aktual, sehingga menegaskan kemampuan model dalam mengikuti pola fluktuasi harga saham, baik pada tren naik, turun, maupun pergerakan mendatar. Di antara ketiga rasio yang diuji, rasio 7:3 memberikan performa terbaik dengan nilai MSE terkecil (0.0006) dan R² Score tertinggi (0.9953), meskipun rasio 8:2 juga menghasilkan prediksi yang sangat optimal dengan RMSE terendah (0.024). Sementara itu, rasio 6:4 tetap menunjukkan hasil yang baik, namun sedikit kurang optimal karena proporsi data latih yang lebih sedikit membuat model kurang maksimal dalam mengenali pola historis. Secara keseluruhan, penelitian ini membuktikan bahwa SVM dengan optimasi parameter mampu menjadi metode yang andal untuk memprediksi harga

penutupan saham ANTM, serta dapat memberikan kontribusi praktis dalam mendukung pengambilan keputusan investasi yang lebih informatif dan strategis.

Namun demikian, penelitian ini memiliki beberapa keterbatasan. Pertama, model hanya menggunakan data historis harga saham tanpa mempertimbangkan faktor eksternal seperti indikator makroekonomi, berita keuangan, atau sentimen pasar yang juga dapat memengaruhi pergerakan harga saham. Kedua, penelitian ini hanya berfokus pada satu jenis saham (ANTM) sehingga generalisasi model terhadap saham lain belum dapat dipastikan. Ketiga, penggunaan kernel RBF sebagai parameter utama pada SVM belum dibandingkan dengan kernel lain yang mungkin memberikan hasil lebih baik. Untuk pengembangan penelitian selanjutnya, disarankan agar model SVM dibandingkan dengan algoritma lain seperti Random Forest, LSTM, atau XGBoost guna melihat keunggulan relatifnya dalam konteks prediksi harga saham. Selain itu, penelitian di masa depan dapat mengintegrasikan data non-numerik seperti teks berita atau indeks sentimen pasar untuk meningkatkan akurasi prediksi. Evaluasi lanjutan juga dapat dilakukan menggunakan analisis residual dan error plot untuk mengidentifikasi pola kesalahan prediksi yang belum tertangkap oleh model.

DAFTAR PUSTAKA

- Aliano, D., Yulianti, O., & Harwini, D. (2024). The Role Of Money Markets In Supporting Economic Growth And Business Capital Development. *JAM Journal of Accounting and Management*, 1(1), 1-4. <https://doi.org/10.70963/jam.v1i1.361>
- Almanaseer, S. (2024). The Impact Of Equity Financing On Financial Performance: Evidence From Jordan. *Foundations of Management*, 16(1), 157–176. <https://doi.org/10.2478/fman-2024-0010>
- Angkoso, C. V., Asror, K., Kusumaningsih, A., & Nugroho, A. K. (2025). Optimasi Algoritma Support Vector Machine Berbasis Kernel Radial Basis Function (RBF) Menggunakan Metode Particle Swarm Optimization Untuk Analisis Sentimen. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 12(3), 705–718. <https://doi.org/10.25126/jtiik.20259317>
- Chang, V., Xu, Q. A., Chidozie, A., & Wang, H. (2024). Predicting Economic Trends and Stock Market Prices with Deep Learning and Advanced Machine Learning Techniques. *Electronics (Switzerland)*, 13(17), 1-27. <https://doi.org/10.3390/electronics13173396>
- Demircioğlu, A. (2024). The Effect Of Feature Normalization Methods In Radiomics. *Insights into Imaging*, 15(1), 1-11. <https://doi.org/10.1186/s13244-023-01575-7>
- Joseph, E., Mishra, A., Rabiu, I. (2019). Forecast on Close Stock Market Prediction using Support Vector Machine (SVM). *International Journal of Engineering Research And*, 8(2), 37–43. <https://doi.org/10.17577/ijertv8is020031>
- Farikhah, F., Tarigan, P., & Sembiring, N. (2021). The Effect of Current Ratio and Net Profit Margin on Share Prices at PT Aneka Tambang Tbk Period 2018 - 2021. *Journal of Accounting and Finance Management*, 2(4), 169–177. <https://doi.org/10.38035/jafm.v2i4.135>
- Izsák, T., Marák, L., & Ormos, M. (2023). Evaluation of Stock Price Prediction Based on the Support Vector. *Applied Computer Science*, 19(3), 64–82. <https://doi.org/10.35784/acs-2023-25>
- Ji, S. (2024). Predict Stock Market Price By Applying ANN, SVM And Random Forest. *SHS Web of Conferences*, 196, 02005. <https://doi.org/10.1051/shsconf/202419602005>
- Li, A., Wei, Q., Shi, Y., & Liu, Z. (2023). Research On Stock Price Prediction From A Data Fusion Perspective. *Data Science In Finance And Economics*, 3(3), 230–250. <https://doi.org/10.3934/dsfe.2023014>
- Liyew, C. M., Di Nardo, E., Ferraris, S., & Meo, R. (2025). Hyperparameter Optimization Of Machine Learning Models For Predicting Actual Evapotranspiration. *Machine Learning with Applications*, 20, 100661. <https://doi.org/10.1016/j.mlwa.2025.100661>

- Joel, L. O., Doorsamy, W., & Paul, B. S. (2022). A Review of Missing Data Handling Techniques for Machine Learning. *International Journal of Innovative Technology and Interdisciplinary Sciences*, 5(3), 971–1005. <https://doi.org/10.15157/IJITIS.2022.5.3.971-1005>
- Rivai, A. (2023). The effect of gold, dollar and Composite Stock Price Index on cryptocurrency. *International Journal of Research in Business and Social Science*, 12(3), 231–236. <https://doi.org/10.20525/ijrbs.v12i3.2561>
- Roy, B., & Yosef, A. (2019). Pertumbuhan Rohani Anak Dalam Keluarga Kristen Menurut Efesus 6:4. *Jurnal Teknologi dan Pendidikan*, 5(1), 52–69. <https://doi.org/10.54793/teologi-dan-kependidikan.v5i1.4>
- Setiawan, I., Gernowo, R., & Warsito, B. (2023). A Systematic Literature Review on Missing Values: Research Trends, Datasets, Methods and Frameworks. *E3S Web of Conferences*, 448. <https://doi.org/10.1051/e3sconf/202344802020>
- Yang, J. (2023). Support Vector Machine-Based Stock Prediction Analysis. *Highlights in Business, Economics and Management*, 3(2023), 12–18. <https://doi.org/10.54097/hbem.v3i.4625>
- Yennimar, Y., Kelvin, K., Suwandi, S., & Amir, A. (2022). Comparison Analysis of SVM Algorithm with Linear Regression in Predicting used Car Prices. *Jurnal Mantik*, 5(4), 2720–2728.