

Klasifikasi Kondisi Pasar Harga Emas ANTAM Indonesia Menggunakan Algoritma *Decision Tree*

Antika Zahrotul Kamalia^{1*}, Choiriyatun Nisa Latansa², Zaenur Rozikin³

^{1,2,3}Fakultas Teknik, Program Studi Teknik Informatika, Universitas Pelita Bangsa, Bekasi, Indonesia
Email: ^{1*}antika.kamalia@pelitabangsa.ac.id, ²c.nisalatansa@gmail.com, ³zaenurrozikin@pelitabangsa.ac.id
(* Email Corresponding Author: antika.kamalia@pelitabangsa.ac.id)

Received: January 17, 2026 | Revision: January 22, 2026 | Accepted: January 24, 2026

Abstrak

Penelitian ini bertujuan mengklasifikasikan kondisi pasar harga emas ANTAM Indonesia menggunakan algoritma *Decision Tree* berbasis data harga harian periode 2010–2024. Kondisi pasar dikelompokkan ke dalam tiga kelas, yaitu *bullish*, *bearish*, dan *sideways*, berdasarkan forward return dengan threshold adaptif berbasis kuantil. Fitur yang digunakan meliputi indikator volatilitas rolling (mis. *std_5*, *std_10*, *std_20*) dan momentum (mis. *mom_5*, *mom_10*, *mom_20*) pada beberapa horizon. Data dipisahkan menggunakan time-based split dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian. Hasil evaluasi pada data uji menunjukkan akurasi 0,337 dengan macro-F1 sekitar 0,34, mengindikasikan bahwa kinerja prediktif model masih terbatas pada klasifikasi tiga kelas. Analisis interpretabilitas menunjukkan bahwa *std_20* merupakan fitur paling dominan, diikuti *std_10* dan *mom_5*, sedangkan return harian tunggal berkontribusi sangat kecil. Temuan ini menegaskan bahwa pola volatilitas dan momentum lebih informatif dibanding perubahan satu-hari dalam memetakan rezim pasar. Secara keseluruhan, *Decision Tree* lebih tepat diposisikan sebagai baseline interpretatif untuk analisis kondisi pasar yang transparan dan mudah ditelusuri, serta menjadi landasan pengembangan model dan fitur yang lebih kuat pada penelitian selanjutnya.

Kata Kunci: Emas, Kondisi pasar, Machine learning, *Decision Tree*, Klasifikasi.

Abstract

*This study aims to classify Indonesian ANTAM gold market states using a Decision Tree model built on daily price data from 2010–2024. Market conditions are categorized into three classes: bullish, bearish, and sideways, based on forward returns with an adaptive quantile-based thresholding scheme. The feature set comprises multi-horizon rolling volatility indicators (e.g., *std_5*, *std_10*, *std_20*) and momentum measures (e.g., *mom_5*, *mom_10*, *mom_20*). A time-based split is applied, allocating 80% of observations for training and 20% for testing. Evaluation on the test set yields an accuracy of 0.337 with a macro-F1 of approximately 0.34, indicating limited predictive performance in a three-class setting. Interpretability analysis reveals that *std_20* is the most influential feature, followed by *std_10* and *mom_5*, while one-day returns contribute marginally. These findings suggest that aggregated volatility and momentum patterns are more informative than single-day fluctuations for market regime mapping. Overall, the Decision Tree is best positioned as an interpretable baseline for transparent market-state analysis, providing a foundation for future work involving richer features and more robust models.*

Keywords: Gold, Market Conditions, Machine learning, *Decision Tree*, Classification.

1. PENDAHULUAN

Emas telah lama dikenal sebagai salah satu instrumen investasi yang paling populer di Indonesia karena sifatnya yang relatif stabil, mudah diakses oleh masyarakat, serta mampu mempertahankan nilai dalam jangka panjang[1]. Produk emas batangan yang diproduksi oleh PT Aneka Tambang Tbk (ANTAM) menjadi pilihan utama investor ritel karena memiliki standar kemurnian tinggi dan tingkat kepercayaan yang kuat di pasar domestik[2]. Popularitas emas sebagai aset lindung nilai (*safe haven*) juga meningkat seiring dengan ketidakpastian ekonomi global dan domestik, sehingga emas sering dijadikan alternatif investasi di tengah fluktuasi pasar keuangan lainnya[3].

Meskipun dikenal relatif stabil, harga emas ANTAM tetap mengalami fluktuasi dari waktu ke waktu yang dipengaruhi oleh berbagai faktor, seperti dinamika harga emas dunia, nilai tukar rupiah terhadap dolar AS, inflasi, serta kondisi geopolitik dan ekonomi global[4]. Dalam periode 2010–2024, harga emas ANTAM menunjukkan pola pergerakan yang beragam, mulai dari fase kenaikan tajam, penurunan signifikan, hingga pergerakan mendatar dalam periode tertentu. Fluktuasi ini menciptakan ketidakpastian bagi investor, khususnya investor ritel, dalam menentukan waktu yang tepat untuk membeli, menahan, atau menjual emas[5].

Dalam konteks investasi, memahami arah pergerakan harga saja tidak selalu cukup. Investor juga perlu memahami kondisi pasar secara lebih luas, seperti apakah pasar sedang berada dalam kondisi *bullish* (menguat), *bearish* (melemah), atau *sideways* (bergerak mendatar)[6]. Klasifikasi kondisi pasar ini penting karena setiap kondisi memerlukan strategi pengambilan keputusan yang berbeda. Tanpa pemahaman kondisi pasar yang memadai, investor berpotensi mengambil keputusan yang kurang optimal dan meningkatkan risiko kerugian[7].

Sebagian besar investor ritel di Indonesia masih mengandalkan analisis sederhana atau intuisi dalam membaca pergerakan harga emas, seperti melihat tren visual atau mengikuti rekomendasi tidak terstruktur dari media sosial. Pendekatan ini sering kali bersifat subjektif dan kurang konsisten, terutama ketika menghadapi data historis yang panjang dan kompleks. Analisis statistik konvensional juga memiliki keterbatasan dalam menangkap pola nonlinier dan interaksi antar variabel yang muncul dalam data harga emas jangka Panjang[8].

Perkembangan machine learning membuka peluang baru dalam analisis pasar keuangan, termasuk pasar komoditas seperti emas. Pendekatan machine learning mampu memanfaatkan data historis dalam jumlah besar untuk menemukan pola tersembunyi yang sulit diidentifikasi melalui metode konvensional[9]. Dalam konteks pasar keuangan, machine learning telah digunakan untuk berbagai tujuan, seperti prediksi harga, deteksi pola volatilitas, serta klasifikasi kondisi pasar berdasarkan karakteristik pergerakan harga[10].

Di antara berbagai algoritma machine learning, *Decision Tree* memiliki keunggulan dalam hal interoperabilitas dan kemudahan pemahaman. Model ini bekerja dengan membentuk aturan keputusan berbasis kondisi tertentu, sehingga hasil klasifikasi dapat dijelaskan secara logis dan transparan[8]. Karakteristik ini menjadikan *Decision Tree* sangat sesuai untuk penelitian yang bertujuan menghasilkan model yang tidak hanya akurat, tetapi juga mudah dipahami oleh pengguna non-teknis, seperti investor ritel atau pengambil keputusan di sektor keuangan[11].

Sebagian besar penelitian terkait emas dan machine learning masih berfokus pada harga emas internasional atau pasar negara maju, sementara kajian khusus mengenai emas ANTAM di Indonesia relatif terbatas. Padahal, karakteristik pasar emas domestik memiliki kekhasan tersendiri yang dipengaruhi oleh faktor lokal, seperti kebijakan ekonomi nasional dan perilaku investor ritel[9]. Oleh karena itu, penelitian yang mengkaji klasifikasi kondisi pasar harga emas ANTAM berbasis data historis Indonesia menjadi penting untuk mengisi celah penelitian yang ada.

Berdasarkan fenomena dan urgensi tersebut, penelitian ini bertujuan untuk mengklasifikasikan kondisi pasar harga emas ANTAM Indonesia ke dalam kategori *bullish*, *bearish*, dan *sideways* menggunakan algoritma *Decision Tree* berdasarkan data historis periode 2010–2024. Kontribusi utama penelitian ini adalah menyediakan pendekatan klasifikasi kondisi pasar yang sederhana, interpretatif, dan aplikatif, sehingga dapat digunakan sebagai alat bantu analisis bagi investor dan praktisi. Dengan demikian, penelitian ini diharapkan mampu memberikan nilai tambah baik dari sisi akademik maupun praktis dalam pengambilan keputusan investasi emas di Indonesia.

2. METODOLOGI PENELITIAN

Tahapan penelitian yang digunakan untuk mengklasifikasikan kondisi pasar harga emas ANTAM Indonesia. Uraian mencakup jenis dan sumber data, tahapan pra-pemrosesan, pembentukan fitur berbasis pergerakan harga historis, penentuan label kondisi pasar, serta proses pemodelan menggunakan algoritma *Decision Tree*. Selain itu, dijelaskan pula metode pemisahan data, parameter model, dan teknik evaluasi yang digunakan untuk menilai kinerja klasifikasi.



Gambar 1. Tahapan Penelitian

2.1. Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan metode machine learning berbasis klasifikasi. Pendekatan kuantitatif dipilih karena penelitian berfokus pada pengolahan data numerik, analisis pola historis, serta pengambilan keputusan berdasarkan hasil perhitungan matematis dan statistik[12]. Tujuan utama penelitian ini adalah untuk mengklasifikasikan kondisi pasar harga emas ANTAM Indonesia ke dalam tiga kategori utama, yaitu *bullish*, *bearish*, dan *sideways*. Klasifikasi ini dilakukan berdasarkan karakteristik pergerakan harga emas yang diamati dari data historis, sehingga dapat memberikan gambaran kondisi pasar secara objektif.

Algoritma *Decision Tree* dipilih sebagai metode klasifikasi karena memiliki sifat interpretatif, yaitu mampu menghasilkan aturan keputusan dalam bentuk pohon yang mudah dipahami[13]. Keunggulan lain dari *Decision Tree* adalah kemampuannya menjelaskan proses pengambilan keputusan secara transparan, sehingga hasil klasifikasi tidak hanya akurat, tetapi juga dapat dipahami oleh pengguna non-teknis, seperti investor pemula atau pengambil keputusan di bidang ekonomi.

2.2. Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa harga harian emas ANTAM Indonesia yang diambil pada periode 2010 hingga 2024 dengan total 4.546 data historis. Data tersebut mencerminkan pergerakan harga emas dalam jangka panjang, sehingga cukup representatif untuk menangkap pola tren dan fluktuasi pasar.

Dataset terdiri atas dua variabel utama, yaitu:

1. Tanggal transaksi (*Date*), yang menunjukkan waktu pencatatan harga emas.
2. Harga emas (*Price*), yang merepresentasikan nilai harga emas ANTAM pada tanggal tertentu.

Tabel 1. Sampel Data Harga Emas

Date	Price (Rp)
1/4/2010	408,000
1/5/2010	410,000
1/6/2010	410,000
.	.
.	.
12/29/2024	1,526,000
12/30/21024	1,528,000
12/31/2024	1,515,000

Data disusun secara kronologis dalam bentuk time-series, sehingga setiap observasi saling berurutan berdasarkan waktu. Data ini digunakan sebagai dasar dalam proses pembentukan fitur serta penentuan label kondisi pasar, yang menjadi target klasifikasi dalam penelitian.

2.3. Pra-pemrosesan Data

Tahap pra-pemrosesan data dilakukan untuk memastikan kualitas dan konsistensi data sebelum dianalisis, Tahap ini bertujuan untuk memastikan bahwa data siap digunakan dalam proses ekstraksi fitur dan pemodelan[14].

Langkah-langkah yang dilakukan meliputi:

1. Konversi kolom tanggal ke format waktu (*datetime*).
2. Penyusunan data secara berurutan berdasarkan waktu.
3. Pemeriksaan nilai hilang (*missing values*) dan penghapusan baris yang tidak memiliki nilai harga.
4. Transformasi tipe data harga ke format numerik.

2.4. Ekstraksi dan Pembentukan Fitur

Ekstraksi dan pembentukan fitur dilakukan untuk memperoleh representasi data yang mampu menangkap pola dan dinamika pergerakan harga emas secara lebih informatif[8]. Fitur-fitur yang digunakan dibentuk berdasarkan informasi historis harga emas, sehingga dapat merefleksikan tren, volatilitas, dan perubahan kondisi pasar. Seluruh fitur dihitung dengan menggunakan data masa lalu (*historical data*) tanpa melibatkan informasi masa depan. Hal ini dilakukan untuk menghindari bias informasi ke depan (*data leakage*), yang dapat menyebabkan hasil model terlihat lebih baik secara tidak realistis[15]. Dengan pembentukan fitur yang tepat, model *Decision Tree* diharapkan mampu mengenali perbedaan karakteristik pergerakan harga yang mencerminkan kondisi pasar *bullish*, *bearish*, maupun *sideways*, sehingga hasil klasifikasi menjadi lebih akurat dan dapat diandalkan.

2.4.1 Return Harian

Return harian digunakan untuk mengukur perubahan harga emas dari satu hari ke hari berikutnya dan dirumuskan sebagai[16]:

$$r_t = \frac{p_t}{p_{t-1}} - 1 \quad (1)$$

Keterangan:

p_t : harga emas ANTAM pada hari ke- t

r_t : return harian

2.4.2 Rata-rata Bergerak (*Moving Average*)

Rata-rata bergerak (*moving average*) digunakan untuk menangkap kecenderungan harga dalam jangka pendek hingga menengah dengan melakukan perataan harga historis pada jendela waktu tertentu[17]. *Simple Moving Average* (SMA) dengan jendela waktu n dirumuskan sebagai:

$$SMA_{t,n} = \frac{1}{n} \sum_{i=0}^{n-1} P_t - i \quad (2)$$

Keterangan:

$SMA_{t,n}$: nilai rata-rata bergerak pada waktu t dengan window n hari

P_t : harga emas pada hari ke- t

n : panjang jendela (jumlah hari yang dirata-ratakan), misalnya $n \in \{5,10,20\}$

i : indeks pergeseran hari ke belakang (lag)

2.4.3 Volatilitas Rolling

Volatilitas *rolling* dihitung sebagai standar deviasi return dalam periode tertentu untuk mengukur tingkat ketidakstabilan harga[18]:

$$\sigma_{t,n} = \sqrt{\frac{1}{n-1} \sum_{i=0}^{n-1} (r_{t-i} - \bar{r}_{t,n})^2} \quad (3)$$

Keterangan:

$\sigma_{t,n}$: volatilitas *rolling* pada waktu ke- t dengan jendela n hari

r_{t-i} : return harian pada waktu ke- $t - i$

$\bar{r}_{t,n}$: rata-rata return harian dalam jendela n

n : panjang jendela waktu (dalam penelitian ini $n \in \{5,10,20\}$)

2.4.4 Momentum Harga

Momentum digunakan untuk merepresentasikan kekuatan pergerakan harga dalam periode n :

$$Mom_{t,n} = \frac{P_t - P_{t-n}}{P_{t-n}} \quad (4)$$

Keterangan:

$Mom_{t,n}$: nilai momentum harga pada waktu ke- t dengan jendela n hari

P_t : harga emas pada waktu ke- t

P_{t-n} : harga emas pada waktu ke- $t - n$

n : panjang jendela waktu (dalam penelitian ini $n \in \{5,10,20\}$)

2.4.5 Z-Score Return

Z-score return digunakan untuk menormalisasi return dan mendeteksi kondisi ekstrem[19]:

$$Z_{t,n} = \frac{r_t - \bar{r}_{t,n}}{\sigma_{t,n}} \quad (5)$$

Keterangan:

$Z_{t,n}$: nilai *z-score return* pada waktu ke- t dengan jendela n

r_t : return harian pada waktu ke- t

$\bar{r}_{t,n}$: rata-rata *return* dalam jendela n hari

$\sigma_{t,n}$: standar deviasi *return* dalam jendela n hari

n : panjang jendela waktu (dalam penelitian ini $n \in \{5,10,20\}$)

2.5. Pembentukan Label Kondisi Pasar

Label kondisi pasar dibentuk berdasarkan *return* masa depan dengan *horizon* waktu H hari, yang dirumuskan sebagai berikut[20]:

$$R_t^{(H)} = \frac{P_{t+H}}{P_t} - 1 \quad (6)$$

Keterangan:

$R_t^{(H)}$: return masa depan pada waktu ke- t

P_{t+H} : harga emas pada waktu ke- $t + H$

P_t : harga emas pada waktu ke- t

H : horizon waktu ke depan (dalam penelitian ini $H = 5$ hari)

Untuk menentukan batas klasifikasi secara adaptif, digunakan threshold berbasis kuantil dari nilai absolut return masa depan:

$$\theta = Q(R_t + H) \quad (7)$$

Selanjutnya, kondisi pasar diklasifikasikan ke dalam tiga kategori sebagai berikut:

$$y_t = \begin{cases} \text{Bullish}, & R_{t+H} > \theta \\ \text{Bearish}, & R_{t+H} < -\theta \\ \text{Sideways}, & R_{t+H} \leq \theta \end{cases} \quad (8)$$

Keterangan:

θ : threshold adaptif berbasis kuantil

$MarketState_t$: label kondisi pasar pada waktu ke- t

Pendekatan ini memungkinkan pembentukan label yang lebih seimbang dan adaptif terhadap karakteristik data.

2.6. Pemisahan Data

Data dalam penelitian ini dipisahkan menjadi data pelatihan (*training data*) dan data pengujian (*testing data*) dengan menggunakan pendekatan *time-based split*. Pendekatan ini membagi data berdasarkan urutan waktu, bukan secara acak, sehingga struktur deret waktu (*time-series*) tetap terjaga. Sebanyak 80% data pada periode awal digunakan sebagai data pelatihan, sedangkan 20% data pada periode akhir digunakan sebagai data pengujian. Data pelatihan dimanfaatkan untuk membangun dan melatih model klasifikasi *Decision Tree*, sementara data pengujian digunakan untuk mengevaluasi kinerja model dalam mengklasifikasikan kondisi pasar pada periode yang belum pernah dilihat sebelumnya[21].

Pemilihan pendekatan *time-based split* bertujuan untuk menghindari kebocoran informasi (*data leakage*), yaitu kondisi ketika model secara tidak langsung mempelajari informasi dari masa depan. Dengan mempertahankan urutan kronologis data, proses evaluasi model menjadi lebih realistis dan mencerminkan kondisi penggunaan model pada data riil di masa mendatang[22].

2.7. Model Decision Tree

Model klasifikasi dibangun menggunakan algoritma *Decision Tree*. Algoritma ini bekerja dengan membentuk struktur pohon keputusan berdasarkan pemilihan atribut yang mampu memisahkan kelas secara optimal. Kriteria pemisahan yang digunakan adalah *Gini impurity*, yang dirumuskan sebagai[23]:

$$Gini(S) = 1 - \sum_{k=1}^K P_k^2 \quad (9)$$

Keterangan:

S : himpunan data pada suatu node

K : jumlah kelas

p_k : proporsi data yang termasuk ke dalam kelas ke- k

Pemilihan split terbaik dilakukan dengan memaksimalkan penurunan impuritas:

$$\Delta Gini = Gini(S) - \sum_{j=1}^m \left| \frac{S_j}{S} \right| Gini(S_j) \quad (10)$$

Keterangan:

S_j : subset data hasil pemisahan

$|S_j|$: jumlah sampel pada subset ke- j

$|S|$: jumlah sampel pada node induk

m : jumlah cabang hasil split.

Untuk menghindari *overfitting*, model dibatasi menggunakan parameter kedalaman maksimum pohon dan jumlah minimum sampel pada daun[24].

2.8. Evaluasi Model

Kinerja model dievaluasi menggunakan metrik akurasi dan *confusion matrix* untuk mengukur kemampuan klasifikasi setiap kondisi pasar[25]. Akurasi dihitung menggunakan rumus:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

Keterangan:

TP: true positive

TN: true negative

FP: false positive

FN: false negative

Masing-masing merepresentasikan hasil prediksi model terhadap data aktual, selain itu, digunakan pula *precision*, *recall*, dan *F1-score* untuk memberikan gambaran kinerja model pada masing-masing kelas.

2.9. Visualisasi Hasil

Visualisasi hasil dilakukan untuk menyajikan keluaran model klasifikasi secara informatif dan mudah dipahami. Visualisasi tidak hanya berfungsi sebagai alat penyajian hasil, tetapi juga sebagai sarana analisis untuk mengevaluasi kinerja model serta memahami pola keputusan yang dihasilkan[26]. Beberapa bentuk visualisasi yang digunakan dalam penelitian ini meliputi:

1. Confusion Matrix

Confusion matrix digunakan untuk menampilkan perbandingan antara hasil prediksi model dan label kondisi pasar yang sebenarnya. Visualisasi ini menunjukkan distribusi jumlah prediksi benar dan salah pada masing-masing kelas, yaitu *bullish*, *bearish*, dan *sideways*. Melalui *confusion matrix*, dapat dianalisis tingkat kesalahan klasifikasi serta performa model dalam membedakan setiap kondisi pasar.

2. Visualisasi Pohon Keputusan

Visualisasi pohon keputusan digunakan untuk menampilkan struktur aturan klasifikasi yang dihasilkan oleh algoritma *Decision Tree*. Setiap simpul (*node*) merepresentasikan aturan pemisahan berdasarkan fitur tertentu, sedangkan cabang menunjukkan keputusan yang diambil. Visualisasi ini bersifat interpretatif dan membantu pengguna memahami logika pengambilan keputusan model secara transparan, khususnya bagi pengguna *non-teknis*.

3. Grafik Pergerakan Harga Emas ANTAM

Grafik harga emas ANTAM divisualisasikan dalam bentuk deret waktu dan dipadukan dengan warna yang merepresentasikan kondisi pasar aktual serta hasil prediksi model. Visualisasi ini bertujuan untuk memperlihatkan kesesuaian antara pola pergerakan harga emas dengan hasil klasifikasi yang dihasilkan oleh model, sehingga dapat diamati bagaimana perubahan harga berkorelasi dengan kondisi pasar yang teridentifikasi.

Secara keseluruhan, visualisasi hasil bertujuan untuk meningkatkan pemahaman terhadap perilaku model, mengevaluasi konsistensi hasil klasifikasi, serta mengkaji implikasi ekonomis dari kondisi pasar yang diidentifikasi. Dengan adanya visualisasi, hasil penelitian diharapkan lebih mudah diinterpretasikan dan memiliki nilai praktis bagi pengambilan keputusan.

3. HASIL DAN PEMBAHASAN

Hasil penerapan metode penelitian yang telah dijelaskan pada bab sebelumnya, termasuk hasil ekstraksi fitur, distribusi kondisi pasar, kinerja model *Decision Tree*, serta interpretasi hasil klasifikasi. Pembahasan difokuskan pada keterkaitan antara hasil empiris dengan tujuan penelitian, interpretasi struktur pohon keputusan, kontribusi fitur, serta implikasi hasil klasifikasi kondisi pasar harga emas ANTAM Indonesia.

3.1. Karakteristik Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data harga harian emas ANTAM Indonesia yang disusun dalam bentuk deret waktu (*time series*). Berdasarkan hasil pemeriksaan struktur data, dataset terdiri atas 4.546 data observasi dengan dua variabel utama, yaitu *Date* dan *Price*. Struktur data deret waktu memungkinkan analisis pergerakan harga secara kronologis dan sesuai untuk kajian pasar keuangan berbasis data historis.

Tabel 2. Ringkasan Struktur dan Kualitas Data

Komponen	Keterangan
Jumlah observasi	4.546
Jumlah variabel	2
Variabel	Date (datetime), Price (int64)
Missing values	0
Bentuk data	Time series harian
Periode	2010–2024

Berdasarkan Tabel 2 Variabel *Date* bertipe *datetime64[ns]*, yang memastikan urutan waktu data dapat dipertahankan pada tahap pemodelan menggunakan pendekatan *time-based split*. Sementara itu, variabel *Price* bertipe *int64* yang merepresentasikan harga emas ANTAM dalam satuan rupiah. Penggunaan harga historis sebagai dasar analisis sejalan dengan prinsip analisis teknikal yang menyatakan bahwa informasi harga masa lalu mencerminkan dinamika dan kondisi pasar suatu aset.

Pemeriksaan kualitas data menunjukkan bahwa dataset tidak mengandung nilai hilang (*missing values*) pada seluruh variabel. Kondisi ini memungkinkan seluruh observasi digunakan tanpa proses imputasi tambahan, sehingga perhitungan indikator turunan seperti *return* dan volatilitas dapat dilakukan secara konsisten. Keberadaan data yang lengkap dan terstruktur secara temporal merupakan prasyarat penting dalam analisis deret waktu dan pemodelan berbasis *machine learning*.

3.2. Distribusi Label Kondisi Pasar

Pembentukan label kondisi pasar pada penelitian ini dilakukan berdasarkan *return* masa depan (*forward return*) dengan *horizon* waktu lima hari, sebagaimana dijelaskan pada Bab Metode. Untuk menentukan batas klasifikasi secara adaptif terhadap karakteristik data, digunakan *threshold* berbasis kuantil sebesar $q = 0,35$ dari nilai *absolut return* masa depan. Hasil perhitungan menunjukkan nilai *threshold* sebesar 0,004854, yang kemudian digunakan sebagai ambang pemisah antara kondisi pasar *bullish*, *bearish*, dan *sideways*. Pendekatan *threshold* adaptif ini memungkinkan klasifikasi kondisi pasar yang lebih sesuai dengan skala volatilitas historis harga emas, dibandingkan penggunaan ambang batas statis.

Tabel 3. Distribusi Label Kondisi Pasar

MarketState	Total
<i>bullish</i>	1609
<i>Sideways</i>	1574
<i>Bearish</i>	1306

Berdasarkan hasil pelabelan pada Tabel 3 tersebut, distribusi kondisi pasar harga emas ANTAM Indonesia menunjukkan bahwa kondisi *bullish* merupakan kelas dengan jumlah observasi terbesar, yaitu 1.609 observasi, diikuti oleh kondisi *sideways* sebanyak 1.574 observasi, dan kondisi *bearish* sebanyak 1.306 observasi. Urutan distribusi ini mengindikasikan bahwa selama periode pengamatan, fase kenaikan harga dalam *horizon* jangka pendek relatif lebih sering terjadi dibandingkan fase penurunan harga, meskipun perbedaannya tidak terlalu ekstrem. Dengan demikian, distribusi kelas yang dihasilkan masih berada dalam kondisi yang relatif seimbang dan tidak menunjukkan masalah *class imbalance* yang signifikan.

Secara konseptual, pola distribusi ini sejalan dengan karakteristik pasar emas yang cenderung mengalami kenaikan harga secara bertahap dalam jangka menengah, diselingi oleh periode konsolidasi dan penurunan harga pada kondisi tertentu. Keberadaan kelas *sideways* yang hampir seimbang dengan kelas *bullish* menunjukkan bahwa pasar emas ANTAM sering berada pada fase stabil, sementara fase *bearish* muncul dengan frekuensi yang lebih rendah. Distribusi label yang relatif seimbang ini juga memberikan keuntungan metodologis dalam proses pemodelan klasifikasi menggunakan *Decision Tree*. Model tidak didominasi oleh satu kelas tertentu, sehingga memiliki peluang yang lebih baik untuk mempelajari pola pembeda antar kondisi pasar secara proporsional. Hal ini penting dalam konteks *machine learning*, karena distribusi kelas yang terlalu timpang dapat menurunkan kemampuan generalisasi model dan menghasilkan bias prediksi.

3.3. Hasil Pemisahan Data Pelatihan dan Pengujian

Pemisahan data dilakukan menggunakan pendekatan *time-based split* dengan proporsi 80% data pelatihan dan 20% data pengujian untuk menjaga urutan temporal data deret waktu. Pendekatan ini dipilih guna menghindari kebocoran informasi dari periode masa depan dan memastikan evaluasi model mencerminkan kondisi penggunaan nyata pada data pasar keuangan. Hasil pemisahan menunjukkan bahwa data pelatihan terdiri atas 3.591 observasi, sedangkan data pengujian terdiri atas 898 observasi, dengan masing-masing observasi memiliki 11 fitur input. Data pelatihan mencakup periode 1 Februari 2010 hingga 8 Juli 2022, sementara data pengujian mencakup periode 9 Juli 2022 hingga 27 Desember 2024. Pembagian ini memungkinkan model mempelajari pola historis jangka panjang sekaligus diuji pada periode pasar yang lebih mutakhir.

3.4. Kinerja Model *Decision Tree*

Model *Decision Tree* dilatih menggunakan fitur-fitur Model *Decision Tree* pada penelitian ini dilatih menggunakan data pelatihan dengan parameter $max_depth = 4$ dan $min_samples_leaf = 30$, sebagaimana ditunjukkan pada CELL 6. Pembatasan kedalaman pohon dan jumlah minimum sampel pada daun bertujuan untuk mengendalikan kompleksitas model sehingga mengurangi risiko *overfitting* serta menjaga interpretabilitas aturan keputusan. Strategi ini sejalan dengan prinsip dasar *Decision Tree* yang menekankan keseimbangan antara kesederhanaan struktur dan kemampuan generalisasi model.

```
*** Accuracy: 0.3374164810690423
Classification Report:
      precision    recall  f1-score   support

 Bearish      0.27      0.44      0.34       242
 Bullish      0.39      0.21      0.27       358
 Sideways     0.38      0.41      0.40       298

 accuracy          0.34       898
 macro avg         0.35       898
 weighted avg      0.36       898
```

Gambar 1. Hasil Kinerja Model

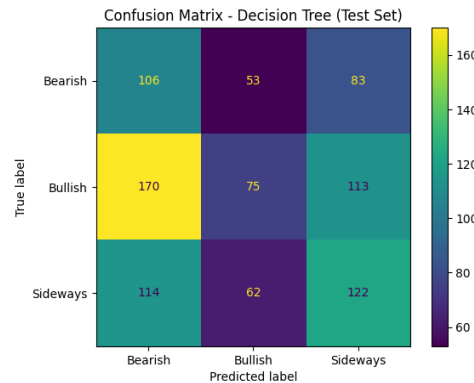
Hasil evaluasi pada Gambar 1 menyatakan bahwa data pengujian menunjukkan bahwa model menghasilkan nilai akurasi sebesar 0,337. Artinya, sekitar 33,7% observasi pada data uji berhasil diklasifikasikan secara tepat ke dalam kondisi pasar *bullish*, *bearish*, atau *sideways*. Namun, karena masalah ini merupakan klasifikasi tiga kelas, nilai tersebut berada mendekati tingkat acak ($\approx 0,333$) dan bahkan lebih rendah dibanding baseline mayoritas pada data uji (selalu memprediksi kelas *bullish* $\approx 0,399$). Hal ini mengindikasikan bahwa *Decision Tree* dengan pembatasan kompleksitas untuk menjaga interpretabilitas cenderung belum menangkap pola pemisahan kelas secara memadai (*underfitting*), yang wajar pada data pasar keuangan yang nonlinier dan dipengaruhi banyak faktor eksternal.

Berdasarkan *classification report*, performa model bervariasi antar kelas. Kelas *bearish* memiliki *recall* relatif lebih tinggi (0,44) sehingga model lebih sensitif dalam menangkap periode penurunan harga. Sebaliknya, kelas *bullish* menunjukkan *recall* yang rendah (0,21), menandakan sebagian periode kenaikan harga sering tertukar menjadi kelas lain, khususnya *sideways*. Kelas *sideways* memperlihatkan *precision* dan *recall* yang relatif seimbang (*precision* 0,38, *recall* 0,41), yang mencerminkan adanya tumpang tindih karakteristik antara fase konsolidasi dan tren lemah. Secara agregat, metrik *macro average* (*precision* $\approx 0,35$, *recall* $\approx 0,35$, $F1 \approx 0,34$) menunjukkan kinerja yang masih terbatas dan lebih representatif dibanding sekadar akurasi pada data yang berpotensi tidak seimbang.

Kinerja model juga berkaitan dengan struktur pohon keputusan yang terbentuk. Pemisahan awal yang didominasi oleh fitur volatilitas dan momentum menunjukkan bahwa model banyak mengandalkan sinyal ketidakstabilan harga dalam menentukan kondisi pasar. Akan tetapi, *overlap* antar kondisi pasar emas terutama antara *bullish* lemah dan *sideways* membatasi kemampuan model dalam menghasilkan prediksi yang kuat. Secara keseluruhan, hasil ini menunjukkan bahwa *Decision Tree* lebih tepat diposisikan sebagai model *baseline* yang interpretatif untuk memberikan gambaran awal dan mengekstraksi aturan keputusan yang transparan, bukan sebagai model prediktif berkinerja tinggi. Oleh karena itu, fokus utama penelitian ini adalah keterjelasan aturan klasifikasi dan pemetaan kondisi pasar yang mudah dipahami, sementara peningkatan kinerja dapat menjadi arah penelitian selanjutnya melalui *time-series cross-validation* (*walk-forward*), penyetelan hiperparameter, penambahan fitur, atau perbandingan dengan model ensemble yang lebih kuat.

3.5. Analisis Confusion Matrix

Evaluasi menggunakan *confusion matrix* memberikan gambaran rinci tentang kinerja klasifikasi pada tiap kelas kondisi pasar. Pada data uji, terlihat bahwa kesalahan klasifikasi masih cukup tinggi antar kelas, terutama antara *bullish* dan *sideways* yang memiliki karakteristik pergerakan harga yang beririsan.

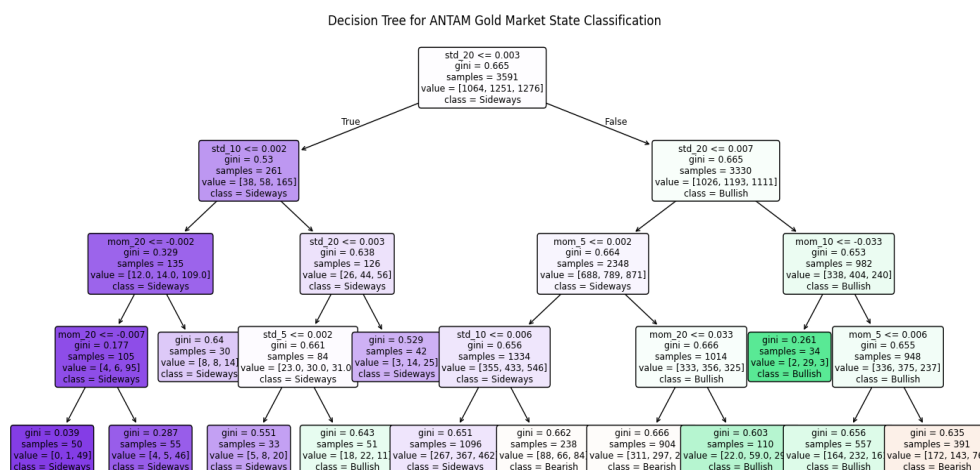


Gambar 2. Hasil *Confusion Matrix*

Berdasarkan Gambar 2, untuk kondisi *bearish*, sebanyak 106 dari 242 observasi berhasil diklasifikasikan dengan benar, sementara sisanya salah diprediksi sebagai *bullish* (53) atau *sideways* (83). Pada kondisi *bullish* (kelas terbesar pada data uji), hanya 75 dari 358 observasi terklasifikasi dengan tepat, dengan sebagian besar salah diprediksi sebagai *bearish* (170) dan *sideways* (113). Sementara itu, kondisi *sideways* menunjukkan performa yang relatif lebih seimbang, dengan 122 dari 298 observasi terklasifikasi benar, sedangkan sisanya salah diprediksi sebagai *bearish* (114) atau *bullish* (62). Pola ini mengindikasikan bahwa model mengalami kesulitan membedakan kondisi pasar pada fase transisi, khususnya ketika sinyal volatilitas dan momentum belum cukup kuat untuk membentuk tren yang jelas.

3.6. Interpretasi Struktur Pohon Keputusan

Visualisasi struktur pohon keputusan menunjukkan bahwa fitur volatilitas *rolling* dan momentum harga menjadi dasar utama pembentukan aturan klasifikasi, terutama pada pemisahan awal yang memprioritaskan dinamika perubahan harga dibandingkan level harga *absolut*.



Gambar 3. Hasil Interpretasi Struktur Pohon Keputusan

Struktur pohon keputusan pada Gambar 3 menunjukkan bahwa pemisahan awal data didominasi oleh fitur volatilitas *rolling* jangka menengah (*std_20*). Node akar memisahkan data berdasarkan tingkat volatilitas harga emas, yang mengindikasikan bahwa ketidakpastian pergerakan harga merupakan sinyal penting dalam membedakan kondisi pasar emas ANTAM. Peran volatilitas sebagai indikator kondisi pasar sejalan dengan literatur yang menempatkan volatilitas sebagai proksi ketidakpastian dan perubahan rezim pasar.

Pada tingkat berikutnya, pohon memanfaatkan kombinasi volatilitas jangka lebih pendek (*std_5*, *std_10*) dan momentum (*mom_5*, *mom_10*, *mom_20*) untuk memperhalus klasifikasi. Fitur momentum berfungsi menangkap arah kecenderungan perubahan harga dalam *horizon* pendek-menengah, sehingga membantu membedakan kondisi *bullish*

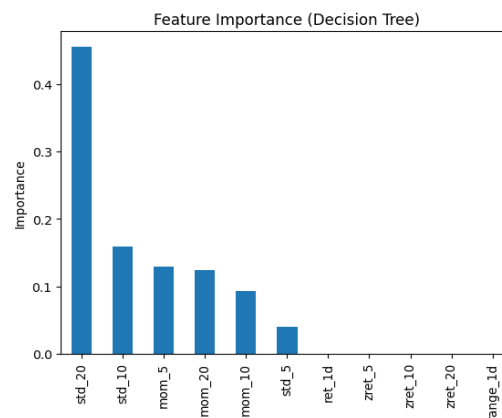
dari *sideways* ketika volatilitas tidak terlalu tinggi. Pola ini konsisten dengan prinsip analisis teknikal yang menggunakan momentum sebagai indikator tren dan *fase* konsolidasi.

Sebagian besar *node* daun pada pohon menunjukkan prediksi kelas *sideways*, terutama pada kondisi volatilitas rendah dan momentum yang lemah. Temuan ini menunjukkan bahwa model cenderung memetakan kombinasi sinyal yang lemah (low-volatility, low-momentum) ke dalam kelas *sideways*, yang secara intuitif merepresentasikan fase konsolidasi. Namun, dominasi prediksi *sideways* pada *node* daun lebih tepat dipahami sebagai karakter aturan keputusan yang dibentuk model, bukan sebagai kesimpulan langsung mengenai frekuensi kondisi pasar pada populasi data.

Secara keseluruhan, struktur pohon yang relatif dangkal mencerminkan kompromi antara kinerja dan interpretabilitas. Pembatasan kedalaman pohon menjaga aturan keputusan tetap mudah ditelusuri, tetapi dapat mengurangi kemampuan model menangkap batas antar kelas yang saling beririsan terutama antara *bullish* lemah dan *sideways* yang sejalan dengan temuan performa klasifikasi yang masih terbatas. Pendekatan ini sesuai dengan tujuan penelitian untuk menghasilkan model klasifikasi kondisi pasar yang transparan dan interpretatif.

3.7. Analisis Kontribusi Fitur

Hasil analisis *feature importance* menunjukkan bahwa fitur volatilitas *rolling* jangka menengah (*std_20*) merupakan faktor paling dominan dalam klasifikasi kondisi pasar harga emas ANTAM Indonesia, dengan nilai kepentingan sebesar 0,4549. Dominasi volatilitas ini mengindikasikan bahwa model lebih banyak memanfaatkan informasi ketidakstabilan harga sebagai sinyal pembeda rezim pasar.




Gambar 4. Hasil Kontribusi Fitur

Berdasarkan Gambar 4 Fitur volatilitas jangka pendek (*std_10*) dan momentum jangka pendek (*mom_5*) juga berkontribusi signifikan, dengan nilai kepentingan masing-masing 0,1588 dan 0,1288. Hal ini menunjukkan bahwa selain tingkat volatilitas, arah dan kekuatan perubahan harga dalam *horizon* pendek turut memengaruhi keputusan klasifikasi. Sebaliknya, fitur *return* harian, *z-score return*, dan rentang perubahan harga harian memiliki kontribusi sangat kecil atau mendekati nol. Temuan ini menunjukkan bahwa, dalam konfigurasi *Decision Tree* dan skema fitur yang digunakan, sinyal satu-hari cenderung kurang dipilih dibandingkan fitur agregatif berbasis *rolling* yang menangkap pola terakumulasi. Perlu dicatat bahwa *feature importance* pada *Decision Tree* (berbasis penurunan *impurity*) bersifat relatif dan dapat dipengaruhi oleh korelasi antar fitur serta karakteristik pembagian data, sehingga interpretasinya lebih tepat sebagai indikasi kecenderungan model, bukan ukuran kausalitas. Untuk memperkuat interpretasi, penelitian lanjutan dapat menggunakan *permutation importance* atau *SHAP* sebagai pembanding.

3.8. Visualisasi Harga dan Kondisi Pasar

Visualisasi harga emas ANTAM pada periode pengujian menampilkan pergerakan harga yang disertai penandaan kondisi pasar aktual (*bullish*, *bearish*, dan *sideways*). Secara visual, fase *bullish* cenderung muncul pada periode kenaikan harga yang berkelanjutan, fase *bearish* pada periode koreksi, dan fase *sideways* pada periode konsolidasi ketika harga bergerak dalam rentang relatif sempit. Pola ini sejalan dengan prinsip analisis teknikal bahwa tren dan fase pasar dapat diidentifikasi dari pergerakan harga historis.



Gambar 5. Hasil Perbandingan Antara Kondisi Pasar Aktual Dan Hasil Prediksi

Perbandingan antara label pada Gambar 5 merupakan kondisi pasar aktual dan hasil prediksi *Decision Tree* menunjukkan bahwa model mampu menangkap sebagian pola umum, terutama pada segmen yang sinyalnya lebih jelas (misalnya konsolidasi dengan volatilitas rendah). Namun, pada fase transisi dan tren naik yang tidak terlalu kuat, perbedaan klasifikasi masih sering terjadi. Hal ini konsisten dengan karakteristik pasar keuangan yang dinamis, di mana perpindahan antar fase sering berlangsung bertahap sehingga batas antar kelas menjadi tidak tegas. Secara keseluruhan, visualisasi ini menegaskan bahwa *Decision Tree* lebih tepat digunakan sebagai alat interpretatif untuk membaca dinamika kondisi pasar berbasis aturan yang transparan, bukan sebagai model prediksi dengan tingkat akurasi tinggi. Oleh karena itu, fungsi utama visualisasi adalah membantu memahami konteks pasar dan area ketidakpastian klasifikasi (misalnya fase transisi), yang dapat menjadi dasar pengembangan model lanjutan dengan fitur atau pendekatan yang lebih kuat.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma *Decision Tree* dapat digunakan untuk mengklasifikasikan kondisi pasar harga emas ANTAM Indonesia ke dalam tiga kategori, yaitu *bullish*, *bearish*, dan *sideways*, berdasarkan fitur teknikal yang diturunkan dari data harga historis. Hasil analisis menegaskan bahwa fitur volatilitas *rolling* dan momentum berperan paling dominan dalam pembentukan aturan klasifikasi, sedangkan fitur perubahan harga harian tunggal memiliki kontribusi yang sangat kecil. Evaluasi pada data uji menghasilkan akurasi 0,337 dengan macro-F1 sekitar 0,34, yang menunjukkan bahwa kinerja prediktif model masih terbatas pada skenario klasifikasi tiga kelas, terutama pada pemisahan fase *bullish* dari fase lain yang cenderung saling beririsan. Meskipun demikian, struktur pohon keputusan yang sederhana dan transparan memberikan nilai tambah dari sisi interpretabilitas, sehingga pendekatan ini lebih tepat diposisikan sebagai baseline interpretatif dan alat bantu analisis kondisi pasar, bukan sebagai alat prediksi yang berorientasi akurasi tinggi. Penelitian selanjutnya disarankan menerapkan validasi *walk-forward*, penyetulan hiperparameter berbasis *Time Series Split*, penambahan fitur yang lebih kaya, serta perbandingan dengan model ensemble untuk meningkatkan kinerja tanpa mengorbankan interpretabilitas secara signifikan.

REFERENCES

- [1] A. Z. Kamalia, "Prediksi Harga Emas Dengan Membandingkan Algoritma Naïve Bayes, K-Nearest Neighbor Dan Support Vector Machine Untuk Meminimalkan Resiko Investasi," President University, 2019.
- [2] R. Ruswana, M. S. Ma'arif, and K. Kirbrandoko, "Kebijakan Strategis Pt. Aneka Tambang Tbk," *J. Apl. Bisnis dan Manaj.*, vol. 6, no. 3, pp. 602–616, 2020, doi: 10.17358/jabm.6.3.602.
- [3] M. Zaenal Asikin, "Peran Emas sebagai Lindung Nilai terhadap Ketidakpastian Pasar Keuangan Global," *Hawalah Kaji. Ilmu Ekon. Syariah*, vol. 3, no. 3, pp. 123–133, 2024, doi: 10.57096/hawalah.v3i3.54.
- [4] A. Ainur, "Pengaruh Ketidakpastian Ekonomi Global Terhadap Inflasi, Kurs, Foreign Direct Investment(Fdi), Harga Emas, Dan Pertumbuhan Ekonomi Di Indonesia," *J. Ekon. Perrjuangan*, vol. 6, no. 1, pp. 43–54, 2024.
- [5] W. Rodrigo *et al.*, "Kausalitas Harga Emas Dunia, Harga Berlian (0,3 Carat, Clarity If-Vvs, Color D- F, Round Brilliant Cut) Dunia, Dan Nilai Tukar Usd Terhadap Return Saham Perusahaan Jewellery Terkemuka Di Dunia," vol. 24, no. 12, 2025.
- [6] I. R. Munthe, B. H. Rambe, S. R. Munthe, S. Subagio, R. Aditiya, and E. F. Susilo, *Inovasi Pemodelan Prediksi Saham dengan CNN-BiGRU dan Attention Untuk Ketepatan Keputusan Berinvestasi*. Sumatera Utara: PT. JASA NIAGA DIGITAL INDONESIA, 2025.
- [7] D. Chaidana *et al.*, "Analisis Ketidakpastian dan Risiko Dalam Investasi," *J. Ilm. Nusant.*, vol. 2, no. 2, pp. 83–93, 2025.
- [8] Yenniemar and G. Br Surbakti, "Prediksi Harga Emas Berdasarkan Finansial Global Dengan Menggunakan Algoritma Gradien Boosting Regression," *Unpri Press*, 2024.
- [9] D. Sunaryo, Hamdan, A. Anggriani, C. Winata, and D. D. Alumi, "Prediksi Tren Risiko Keuangan Perusahaan Berdasarkan Model Machine Learning (Arima) : Tinjauan Literatur," vol. 32, no. 3, pp. 167–186, 2025.

- [10] A. F. Alkayes and T. Sugihartono, "Perbandingan Algoritma XGBoost dan LSTM dalam Prediksi Harga Saham Tesla Menggunakan Data Tahun 2025," *J. Pendidik. dan Teknol. Indones.*, vol. 5, no. 6, pp. 1563–1573, 2025, doi: 10.52436/1.jpti.836.
- [11] R. N. Ramadhon, A. Ogi, A. P. Agung, R. Putra, S. S. Febrihartina, and U. Firdaus, "Implementasi Algoritma Decision Tree untuk Klasifikasi Pelanggan Aktif atau Tidak Aktif pada Data Bank," *Karimah Tauhid*, vol. 3, no. 2, pp. 1860–1874, 2024, doi: 10.30997/karimahtauhid.v3i2.11952.
- [12] M. Fajar, S. Adam, B. Putra, S. I. Puteri, A. Fajrissiddiq, and L. Sani, "Eksplorasi dan Analisis Data Mining untuk Prediksi Pola Konsumen Menggunakan Teknik Klasifikasi dan Clustering," *Sentim. (Seminar Nas. Teknol. Informasi, Mekatronika dan Ilmu Komputer) Univ. Nusa Putra, 17 Mei 2025 Eksplor.*, 2025.
- [13] H. Purnomo, R. E. Pambudi, and R. Irawan, "Penerapan Decision Tree untuk Klasifikasi Penyakit Berdasarkan Data Rekam Medis Hendri," *J. Internet Softw. Eng.*, vol. 2, no. 1, pp. 1104–1116, 2023, [Online]. Available: <https://doi.org/10.55338/saintek.v5i2.2347%0Ahttps://doi.org/10.1016/j.csa.2023.100031%0Ahttps://jurnal.itte.web.id/index.php/jibs/index%0Ahttps://ejournal.bsi.ac.id/ejurnal/index.php/ijse/article/view/11091%0Ahttp://jti.aisyahuniversity.ac.id/index.php/A>
- [14] R. Saputra, Yuhandri, and S. Arlis, "Sistem Deteksi Kepuasan Pelanggan dengan Teknik Pengelolaan Citra Menggunakan Convolutional Neural Networks," *J. Pustaka AI*, vol. 5, no. 2, pp. 324–334, 2025, [Online]. Available: <https://jurnal.pustakagalerimandiri.co.id/index.php/pustakaaiDOI:https://doi.org/10.55382/jurnalpustakaai.v5i2.1219>
- [15] I. Farisi, J. Shadiq, W. Priyadi, D. Maulana, A. Acep, and S. F. Gusril, "Penerapan Model Recurrent Neural Network (RNN) untuk Prediksi Curah Hujan Berbasis Data Historis," *Inf. Syst. Educ. Prof. J. Inf. Syst.*, vol. 9, no. 2, p. 217, 2024, doi: 10.51211/isbi.v9i2.3280.
- [16] Fathoni, M. A. Irwansyah, A. Triana, E. D. Simanullang, Y. N. Alinda, and A. Ibrahim, "Prediksi Harga Dan Volatilitas Emas Dunia Harian: Perbandingan Model Garch Dan Long Short-Term Memory," *Zo. J. Sist. Inf.*, vol. 7, no. 2, pp. 466–475, 2025.
- [17] Sofyan Rahmad, "Prediksi Tren Momen Penjualan pada Minimarket Menggunakan Metode Moving Average dan Trend Moment," *It (Informatic Tech. J.*, vol. 13, no. Vol. 13 No. 1 (2025): IT Journal, pp. 14–26, 2025.
- [18] M. Maksar, "Prediktabilitas Sample Skewness Terhadap Return Pasar Saham Indonesia," *Distribution*, vol. 22, no. 1, pp. 3–7, 2023.
- [19] Safira Cintyarani and N. K. Indrawati, "Prediksi Financial Distress Dengan Model Altman, Zmijewski, Grover, Dan Springate," *Manag. Anal. J.*, vol. 0, no. 0, pp. 1–15, 2022.
- [20] A. Arman, *Manajemen pasar modal untuk pemula*. Jepara: UNISNU Press, 2022.
- [21] T. Novianti, S. A. Mandati, and E. K. Andana, "Peningkatan Evaluasi Risiko Kredit Menggunakan Decision Tree C 4.5," *J. Manuf. Ind. Eng. Technol.*, vol. 2, no. 2, pp. 1–9, 2023, doi: 10.30651/mine-tech.v2i2.21749.
- [22] S. Y. Nailendra, W. Witanti, and G. Abdillah, "Optimasi Prediksi Penjualan Retail Online Menggunakan LightGBM dan Hyperparameter Tuning," pp. 1931–1942, 2025, doi: 10.33364/algoritma/v.22-2.2551.
- [23] D. Muriyatmoko, A. Musthafa, and M. H. Wijaya, "Klasifikasi Profil Kelulusan Nilai AKPAM Dengan Metode Decision Tree," *Semin. Nas. Sains dan Teknol. 2024 Fak.*, no. April, pp. 448–453, 2024.
- [24] T. Latifah and G. D. Anggitha, "Implementasi Metode Random Forest , KNN (K-Nearest Neighbour), Decision Tree e Classification menggunakan Machine Learning untuk Stroke Prediction," *Stat. Dep. ITS Surabaya*, pp. 1–18, 2021.
- [25] A. F. Azmi and A. Voutama, "Prediksi Churn Nasabah Bank Menggunakan Klasifikasi Random Forest Dan Decision Tree Dengan Evaluasi Confusion Matrix," *Komputa J. Ilm. Komput. dan Inform.*, vol. 13, no. 1, pp. 111–119, 2024, doi: 10.34010/komputa.v13i1.12639.
- [26] L. Pambudi and S. Sefrika, "Klasifikasi Dampak dan Kondisi Pasien Hepatitis Menggunakan Metode Decision Tree," *RIGGS J. Artif. Intell. Digit. Bus.*, vol. 4, no. 3, pp. 4769–4775, 2025, doi: 10.31004/riggs.v4i3.2692.
- [27] E. S. Hadi, "Dinamika Pasar Keuangan Syariah Dan Konvensional Di Indonesia :," *J. Astina Mandiri*, vol. 3, no. November, pp. 404–412, 2024.