Journal of Computer and Information System (J-CIS)
Vol.9, No.1, October 2026, Page 248-261
ISSN (print): 2622-5859, ISSN (online): 2622-0881
DOI: https://doi.org/10.31605/jcis.v9i2

Prediksi Tren Perubahan Harga Emas Menggunakan Deret Waktu dan Representasi Citra

Astrid Dewi Maulana Rosalina*[1], Monica Cinthya[2]
[1-2]Program Studi Sistem Informasi, Universitas Negeri Surabaya
E-mail: *[1]astriddewi.22001@mhs.unesa.ac.id, [2]monicacinthya@mhs.unesa.ac.id

Abstrak

Prediksi arah pergerakan harga emas kompleks karena harga fluktuatif, nonlinier, dan dipengaruhi berbagai faktor pasar. Penelitian ini membandingkan model LSTM, CNN, dan Hybrid CNN-LSTM pada representasi Raw Time Series dan Gramian Angular Field (GAF), serta mengkaji apakah GAF meningkatkan kinerja secara konsisten pada berbagai arsitektur. Penelitian menggunakan metodologi CRISP-DM hingga tahap evaluasi. Data harga emas dan tujuh variabel eksternal periode 2017–2025 diperoleh dari Yahoo Finance melalui yfinance. Setelah melalui tahap prapemrosesan, feature engineering, dan pelabelan, data dibagi secara kronologis menjadi 1.225 data latih, 501 data validasi, dan 501 data uji. Data dibentuk menggunakan sliding window berukuran 14; untuk GAF, setiap fitur ditransformasikan menggunakan Gramian Angular Summation Field (GASF) menjadi citra 14 × 14. Enam skenario dibentuk dari kombinasi tiga arsitektur dan dua representasi data. Evaluasi menggunakan balanced accuracy dengan threshold optimal dari data validasi. Balanced accuracy LSTM pada Raw Time Series dan GASF masing-masing 50,46% dan 48,64%. CNN memperoleh 49,08% pada Raw Time Series dan 50,66% pada GASF, sedangkan Hybrid CNN-LSTM masing-masing memperoleh 49,96% dan 52,58%. Hybrid CNN-LSTM berbasis GASF menghasilkan nilai tertinggi, tetapi kinerja klasifikasinya masih terbatas.

***Kata kunci**: Harga Emas, GAF, LSTM, CNN, Hybrid CNN-LSTM*

Abstract

Predicting gold price movements is challenging because prices are volatile, nonlinear, and influenced by various market factors. This study compares LSTM, CNN, and Hybrid CNN-LSTM models using Raw Time Series and Gramian Angular Field (GAF) representations to examine whether GAF consistently improves performance across different architectures. The study adopts the CRISP-DM methodology through the evaluation stage. Gold price data and seven external variables from 2017 to 2025 were obtained from Yahoo Finance using yfinance. Following preprocessing, feature engineering, and labeling, the data were chronologically divided into 1,225 training samples, 501 validation samples, and 501 test samples. The data were organized using a sliding window of 14 time steps. For the image-based representation, each feature was transformed into a 14 × 14 image using the Gramian Angular Summation Field (GASF). Six experimental scenarios were constructed by combining three architectures with two data representations. Model performance was evaluated using balanced accuracy, with the optimal threshold determined from the validation data. The balanced accuracy of LSTM using Raw Time Series and GASF was 50.46% and 48.64%, respectively. CNN achieved 49.08% with Raw Time Series and 50.66% with GASF, while Hybrid CNN-LSTM achieved 49.96% and 52.58%, respectively. Hybrid CNN-LSTM with GASF achieved the highest balanced accuracy; however, its classification performance remained limited.

Keywords: *Gold Price, GAF, LSTM, CNN, Hybrid CNN-LSTM*

1. PENDAHULUAN

Emas merupakan aset *safe haven* yang cenderung mempertahankan nilai di tengah ketidakpastian ekonomi dan tekanan pasar [1,2]. Namun, pandemi COVID-19, stimulus ekonomi, pelonggaran moneter, inflasi, dan ketegangan geopolitik turut meningkatkan fluktuasi harga emas [3]–[5]. Konflik Rusia–Ukraina dan AS-Tiongkok juga mendorong permintaan emas sebagai aset aman serta berdampak pada rantai pasok, harga minyak, dan inflasi global [6,7], sehingga pergerakan harga emas menjadi semakin dinamis dan kompleks untuk diprediksi. Ketidakpastian kebijakan moneter, perubahan suku bunga, *forward guidance*, dan pelemahan dolar AS turut memengaruhi volatilitas serta permintaan emas [8,9]. Oleh karena itu, penelitian ini menggunakan harga minyak mentah, gas alam, perak, tembaga, indeks dolar AS, S&P 500, dan Dow Jones sebagai variabel eksternal. Sifat harga emas yang fluktuatif dan nonlinier juga mendorong penggunaan pendekatan yang mampu mempelajari pola kompleks pada data deret waktu, mengingat metode klasik seperti ARIMA memiliki keterbatasan dalam memodelkan pola nonlinier tertentu [10].

Metode *machine learning*, seperti *Support Vector Machine* (SVM), *Random Forest*, dan *Extreme Gradient Boosting* (XGBoost), telah digunakan dalam prediksi finansial. Namun, penelitian terdahulu menunjukkan bahwa *Long Short-Term Memory* (LSTM) memberikan kinerja yang baik dibandingkan beberapa metode prediksi lainnya [11]. LSTM mampu mempelajari ketergantungan temporal melalui mekanisme *input gate*, *forget gate*, dan *output gate* [12,13], sehingga relevan untuk mempelajari pola temporal harga emas [14,15]. Namun, kinerjanya dapat dipengaruhi oleh arsitektur dan pengaturan *hyperparameter*, serta LSTM tidak secara khusus dirancang untuk mengekstraksi pola lokal [16]. Sebaliknya, *Convolutional Neural Network* (CNN) mampu mengekstraksi pola lokal melalui operasi konvolusi dan telah digunakan dalam analisis data finansial [17]–[19], tetapi CNN konvensional tidak secara khusus dirancang untuk mempelajari ketergantungan temporal jangka panjang. *Hybrid* CNN-LSTM menggabungkan kemampuan ekstraksi pola lokal CNN dengan kemampuan LSTM dalam mempelajari ketergantungan temporal dan telah digunakan dalam berbagai permasalahan prediksi finansial [20].

Selain pemilihan arsitektur, representasi data juga perlu diperhatikan. Deret waktu harga emas memuat fluktuasi, perubahan tren, dan hubungan antarwaktu yang dapat menjadi informasi bagi proses pembelajaran model. Salah satu pendekatan untuk merepresentasikan hubungan tersebut adalah *time series imaging*, yaitu mengubah data deret waktu menjadi citra dua dimensi [21]–[23]. *Gramian Angular Field* (GAF) memetakan nilai deret waktu ke dalam ruang sudut dan membentuk matriks yang merepresentasikan hubungan antar titik waktu [24]. Penelitian ini menggunakan *Gramian Angular Summation Field* (GASF), salah satu varian GAF yang membentuk representasi berdasarkan penjumlahan sudut. Representasi ini memungkinkan hubungan antarwaktu disajikan dalam bentuk citra dua dimensi yang dapat diproses oleh CNN, sedangkan LSTM dapat digunakan untuk mempelajari urutan temporal baik dari data numerik maupun dari fitur yang disusun berdasarkan representasi GAF.

Meskipun CNN, LSTM, *Hybrid* CNN-LSTM, dan *Gramian Angular Field* (GAF) telah digunakan dalam penelitian terkait data finansial, perbandingan kinerja ketiga arsitektur tersebut pada representasi *Raw Time Series* dan GAF untuk klasifikasi arah pergerakan harga emas masih perlu dikaji lebih lanjut. Penggunaan representasi GAF tidak serta-merta menjamin peningkatan kinerja pada setiap arsitektur, karena masing-masing model memiliki karakteristik pembelajaran yang berbeda. CNN dirancang untuk mengekstraksi pola lokal, LSTM mempelajari

ketergantungan temporal, sedangkan *Hybrid* CNN-LSTM menggabungkan kedua kemampuan tersebut. Oleh karena itu, diperlukan perbandingan untuk mengevaluasi variasi kinerja setiap arsitektur ketika menggunakan representasi data yang berbeda. Penelitian ini membandingkan enam skenario, yaitu LSTM, CNN, dan *Hybrid* CNN-LSTM, masing-masing menggunakan representasi *Raw Time Series* dan GAF. Perbandingan dilakukan menggunakan data multivariat, definisi target yang sama, pembagian data secara kronologis, serta prosedur evaluasi yang konsisten, dengan bentuk masukan yang disesuaikan terhadap karakteristik setiap arsitektur. Kinerja setiap skenario dievaluasi menggunakan *Balanced Accuracy* untuk menilai keseimbangan kemampuan model dalam mengklasifikasikan kelas kenaikan dan penurunan harga emas. Dengan demikian, kebaruan penelitian ini terletak pada evaluasi komparatif enam kombinasi arsitektur dan representasi data dalam klasifikasi arah pergerakan harga emas, khususnya untuk mengetahui apakah penggunaan GAF memberikan hasil yang konsisten pada ketiga arsitektur tersebut.

2. METODE

Penelitian ini menggunakan metodologi *Cross-Industry Standard Process for Data Mining* (CRISP-DM) yang diadaptasi hingga tahap evaluasi. Tahapan penelitian meliputi *business understanding*, *data understanding*, *data preparation*, *modeling*, dan *evaluation*. Alur penelitian disajikan pada Gambar 1.

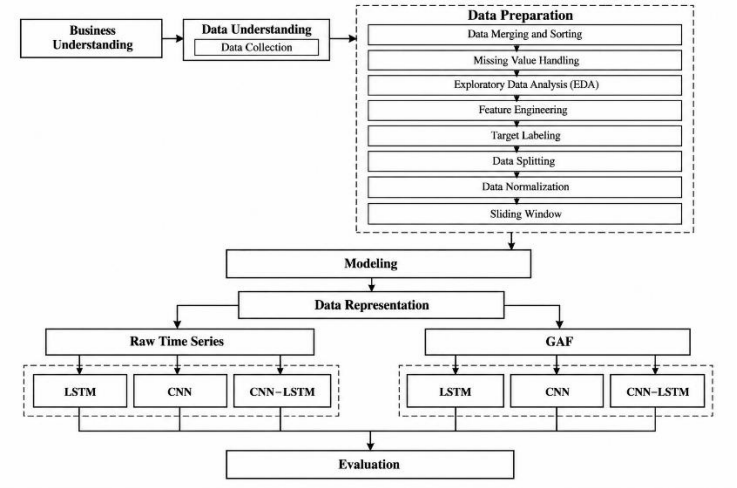

Gambar 1 Alur Tahapan Penelitian

Pada tahap *business understanding*, penelitian difokuskan pada klasifikasi arah pergerakan harga emas menggunakan data historis dan variabel eksternal. *Data understanding* dilakukan terhadap data sekunder yang diperoleh dari Yahoo Finance menggunakan Python dan pustaka yfinance untuk periode 2017–2025. Data harga emas menggunakan *Gold Futures* (GC=F) dengan atribut Open, High, Low, dan Close, sedangkan variabel eksternal terdiri atas harga minyak mentah, gas alam, perak, tembaga, US Dollar Index, S&P 500, dan Dow Jones. Data variabel eksternal menggunakan harga penutupan (*Close*).

Tahap *data preparation* diawali dengan penggabungan dataset berdasarkan tanggal menggunakan *inner join*, pengurutan data secara kronologis, serta pemeriksaan dan penanganan *missing value*. Penanganan *missing value* dilakukan menggunakan metode dropna() dari pustaka *pandas* pada Python untuk menghapus baris yang mengandung nilai kosong. Selanjutnya, *exploratory data analysis* (EDA) dilakukan melalui statistik deskriptif dan visualisasi harga penutupan emas (*Close*). Statistik deskriptif digunakan untuk mengetahui karakteristik dan rentang nilai variabel, sedangkan visualisasi harga digunakan untuk mengamati fluktuasi harga selama periode pengamatan. EDA memberikan gambaran awal mengenai karakteristik dan dinamika data sebelum dilakukan *feature engineering* dan pemodelan.

Feature engineering dilakukan dengan membentuk 21 fitur tambahan dari 11 variabel awal sehingga diperoleh 32 fitur. Fitur tersebut mencakup *return*, *candlestick*, tren, volatilitas, indikator teknikal, dan *Bollinger Bands*. Rincian fitur disajikan pada Tabel 1.

Tabel 1 Hasil Kelompok *Feature Engineering*

Kelompok Fitur	Jumlah	Nama Fitur
Variabel Awal	11	Open, High, Low, Close, Oil_Price, Gas_Price, Silver_Price, Copper_Price, Dollar_Index, Stock_Index, DowJonesIA_Index
Return	8	Gold_Return, Oil_Return, Gas_Return, Silver_Return, Copper_Return, Dollar_Return, Stock_Return, DowJonesIA_Return
Candlestick	4	Body, Range, Upper_Shadow, Lower_Shadow
Trend	2	MA5, MA10
Volatilitas	1	Volatility_5
Momentum	4	RSI, MACD, MACD_Signal, ATR
Bollinger Bands	2	BB_Upper, BB_Lower
Total fitur tambahan	21	
Total fitur setelah feature engineering	32	

Fitur *return* merepresentasikan perubahan nilai antarperiode, sedangkan fitur *candlestick* menggambarkan karakteristik pergerakan harga. MA5 dan MA10 merepresentasikan tren; Volatility_5 mengukur volatilitas; ATR, RSI, MACD beserta MACD_Signal merupakan indikator teknikal momentum; serta BB_Upper dan BB_Lower menunjukkan batas *Bollinger Bands*. Nilai kosong akibat pembentukan fitur diperiksa dan ditangani sebelum pemodelan.

Pelabelan target didasarkan pada perubahan harga penutupan emas. Target bernilai 1 jika harga penutupan hari berikutnya lebih tinggi daripada hari ini, dan 0 jika harga tidak naik, termasuk ketika turun atau tetap. Data kemudian dibagi secara kronologis menjadi data latih, validasi, dan uji tanpa pengacakan (*shuffle*). Normalisasi menggunakan *Min-Max Scaling* dengan rentang 0–1. *Scaler* dipelajari dari data latih, kemudian diterapkan pada data validasi dan uji.

Data dinormalisasi selanjutnya dibentuk menggunakan *sliding window* sepanjang 14 *time step*. Setiap sampel memiliki 14 pengamatan dengan 32 fitur sehingga menghasilkan input *Raw Time Series* berukuran 14 × 32. Data tersebut juga ditransformasikan menjadi citra menggunakan *Gramian Angular Summation Field* (GASF) sebagaimana pada Gambar 2.

.

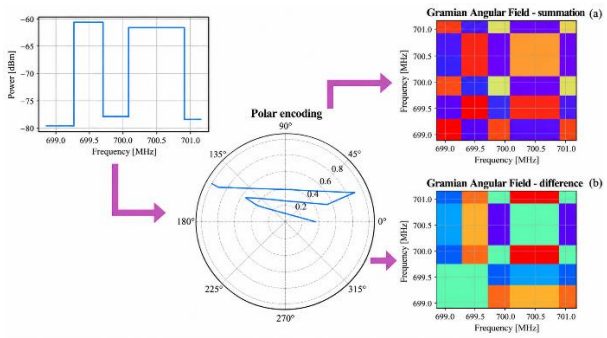

Gambar 2 Gramian Angular Field

GASF memetakan urutan nilai ke representasi sudut dan membentuk matriks berdasarkan penjumlahan sudut antarwaktu. Setiap fitur dalam satu *window* ditransformasikan menjadi matriks berukuran 14 × 14. Matriks dari 32 fitur kemudian disusun sebagai kanal citra sehingga menghasilkan input berukuran 14 × 14 × 32.

Tahap *modeling* membandingkan enam skenario, yaitu LSTM, CNN, dan *Hybrid* CNN-LSTM pada representasi *Raw Time Series* dan GASF. CNN 1D digunakan untuk data deret waktu, sedangkan CNN 2D digunakan untuk citra GASF. Ringkasan arsitektur model disajikan pada Tabel 2.

Tabel 2 Skenario dan Arsitektur Model

Skenario	Input	Arsitektur Utama
LSTM *Raw*	14 × 32	LSTM (64), Dropout (0,2), Dense (24, ReLU), Output (Sigmoid).
CNN 1D *Raw*	14 × 32	Conv1D (64, kernel 3), Batch Normalization, MaxPooling1D, Global Average Pooling, Dropout (0,2), Dense (24, ReLU), Output (Sigmoid).
Hybrid CNN-LSTM *Raw*	14 × 32	Conv1D (64, kernel 3), Batch Normalization, MaxPooling1D, LSTM (64), Dropout (0,2), Dense (24, ReLU), Output (Sigmoid).
LSTM GASF	14 × 14 × 32	Reshape (14 × 448), LSTM (64), Dropout (0,2), Dense (24, ReLU), Output (Sigmoid).
CNN GASF	14 × 14 × 32	Conv2D (64, kernel 3 × 3), Batch Normalization, MaxPooling2D, Global Average Pooling, Dropout (0,2), Dense (24, ReLU), Output (Sigmoid).
Hybrid CNN-LSTM GASF	14 × 14 × 32	Conv2D (64, kernel 3 × 3), Batch Normalization, MaxPooling2D, Reshape (7 × 448), LSTM (64), Dropout (0,2), Dense (24, ReLU), Output (Sigmoid).

Catatan: Angka dalam tanda kurung menunjukkan jumlah unit/filter atau nilai parameter.

Pada skenario LSTM-GASF, citra berukuran 14 × 14 × 32 diubah menjadi urutan berukuran 14 × 448 agar dapat diproses oleh LSTM. Pada skenario *Hybrid* CNN-LSTM-GASF, fitur spasial diekstraksi terlebih dahulu oleh CNN 2D, kemudian hasilnya diubah menjadi urutan untuk diproses oleh LSTM. Lapisan keluaran sigmoid menghasilkan probabilitas kelas Naik yang selanjutnya dikonversi menjadi kelas berdasarkan nilai *threshold*.

Seluruh model dilatih menggunakan optimizer Adam dengan *learning rate* 0,0001, fungsi *binary cross-entropy*, *batch size* 16, dan maksimum 50 *epoch*. Pelatihan menggunakan *Early*

Stopping dengan pemantauan *validation loss*, *patience* 10, dan pemulihan bobot terbaik, serta *ReduceLROnPlateau* dengan faktor 0,5, *patience* 5, dan *minimum learning rate* 0,00001.

Tahap *evaluation* menggunakan *accuracy*, *precision*, *recall*, *F1-score*, dan *balanced accuracy* (BA), serta *confusion matrix*. BA ditetapkan sebagai metrik utama karena memperhitungkan kemampuan model dalam mengenali kedua kelas. Penentuan batas klasifikasi dilakukan dengan menguji *threshold* pada data validasi dari 0 hingga 1 dengan interval 0,001. Nilai yang menghasilkan BA tertinggi pada data validasi dipilih sebagai *threshold* optimal, kemudian diterapkan pada data uji. Dengan demikian, data uji tidak digunakan untuk memilih *threshold*.

3. HASIL DAN PEMBAHASAN

Dataset penelitian diperoleh dari Yahoo Finance melalui pustaka *yfinance* dengan periode pengamatan Januari 2017 hingga Desember 2025. Data awal merupakan hasil penggabungan data harga emas dan variabel eksternal melalui proses *inner join*, sehingga diperoleh 2.261 baris data dengan 11 variabel awal. Selanjutnya, dilakukan *feature engineering* dengan menambahkan 21 fitur yang mencakup *return*, fitur *candlestick*, *moving average*, volatilitas, serta indikator teknikal. Dengan demikian, jumlah fitur yang digunakan dalam proses pemodelan menjadi 32 fitur.

Penanganan nilai kosong dilakukan setelah pembentukan fitur menggunakan pustaka pandas untuk menghapus baris data yang mengandung nilai kosong. Proses tersebut menghasilkan 2.228 baris data. Selanjutnya, pelabelan target dilakukan berdasarkan perubahan harga penutupan emas pada hari berikutnya. Kelas 1 menunjukkan kenaikan harga penutupan, sedangkan kelas 0 menunjukkan harga penutupan yang tidak naik. Karena observasi terakhir tidak memiliki nilai harga penutupan pada hari berikutnya, jumlah data berlabel yang digunakan dalam penelitian ini menjadi 2.227 observasi.

Data kemudian dibagi secara kronologis menjadi data latih, validasi, dan pengujian tanpa pengacakan (*shuffle*). Pembagian ini bertujuan mempertahankan urutan temporal dan mengurangi risiko kebocoran informasi dari periode mendatang ke periode sebelumnya. Distribusi kelas pada setiap subset disajikan pada Tabel 3.

Tabel 3 Distribusi Data Berdasarkan Pembagian dan Kelas Target

Jenis Data	Periode	Kelas 0 (Turun/Tidak Naik)	Kelas 1 (Naik)	Jumlah Data
Data Latih (*Training*)	2017/02/21 – 2021/12/31	567 (46,29%)	658 (53,71%)	1.225
Data Validasi (*Validation*)	2022/01/03 – 2023/12/29	244 (48,70%)	257 (51,30%)	501
Data Uji (*Testing*)	2024/01/02 – 2025/12/30	211 (42,12%)	290 (57,88%)	501
Total	2017 – 2025	1.022	1.205	2.227

Berdasarkan Tabel 3, data latih terdiri atas 567 observasi kelas 0 (46,29%) dan 658 observasi kelas 1 (53,71%). Data validasi terdiri atas 244 observasi kelas 0 (48,70%) dan 257 observasi kelas 1 (51,30%). Sementara itu, data uji terdiri atas 211 observasi kelas 0 (42,12%) dan 290 observasi kelas 1 (57,88%). Distribusi tersebut menunjukkan bahwa proporsi kelas pada data uji berbeda dari kedua subset lainnya, sehingga evaluasi perlu mempertimbangkan kemampuan model dalam mengenali kedua kelas. Pembagian secara kronologis tetap dipertahankan untuk memastikan bahwa periode pengujian berada setelah periode pelatihan dan validasi.

Normalisasi dilakukan menggunakan *MinMaxScaler* dengan rentang 0–1. Parameter *scaler* dipelajari hanya dari data latih, kemudian diterapkan pada data validasi dan uji. Data

selanjutnya dibentuk menggunakan *sliding window* berukuran 14 *time step*. Karena pembentukan *window* dilakukan secara terpisah pada setiap subset, diperoleh 1.212 *sequence* pada data latih serta masing-masing 488 *sequence* pada data validasi dan uji. Setiap *sequence* terdiri atas 14 *time step* dan 32 fitur, sehingga masukan pada representasi *Raw Time Series* berukuran 14 × 32.

Untuk representasi citra, setiap fitur dalam *sequence* ditransformasikan secara terpisah menggunakan *Gramian Angular Summation Field* (GASF) menjadi matriks berukuran 14 × 14. Matriks dari 32 fitur kemudian disusun sebagai kanal citra sehingga menghasilkan masukan berukuran 14 × 14 × 32. Dengan demikian, enam skenario eksperimen dibentuk melalui kombinasi tiga arsitektur, yaitu LSTM, CNN, dan *Hybrid* CNN-LSTM, dengan dua representasi data, yaitu *Raw Time Series* dan GASF.

Setelah pembentukan masukan untuk keenam skenario eksperimen, analisis dilakukan terhadap probabilitas prediksi yang dihasilkan model pada data latih, validasi, dan pengujian. Analisis ini bertujuan mengamati sebaran probabilitas prediksi sebelum hasil klasifikasi dibahas berdasarkan metrik evaluasi. Sebagai contoh, Tabel 4 menyajikan statistik probabilitas prediksi model LSTM pada representasi *Raw Time Series*.

Tabel 4 Distribusi Probabilitas Prediksi Model LSTM Raw *Time Series*

Jenis Data	Minimum	Maksimum	Mean	Std
Training	0,5290	0,5933	0,5508	0,0113
Validation	0,5448	0,5952	0,5678	0,0088
Testing	0,4425	0,5829	0,5319	0,0293

Model *Long Short-Term Memory* (LSTM) pada representasi *Raw Time Series* menghasilkan probabilitas prediksi pada data latih dalam rentang 0,5290–0,5933 dengan rata-rata 0,5508, sedangkan pada data validasi berada pada rentang 0,5448–0,5952 dengan rata-rata 0,5678. Pada data pengujian, probabilitas prediksi berada pada rentang 0,4425–0,5829 dengan rata-rata 0,5319. Rentang tersebut menunjukkan bahwa probabilitas prediksi sebagian besar berada di sekitar 0,5, sehingga keputusan kelas dapat berubah ketika batas klasifikasi disesuaikan.

Tabel 5 Distribusi Probabilitas Prediksi Model CNN 1D Raw *Time Series*

Jenis Data	Minimum	Maksimum	Mean	Std
Training	0,4426	0,5599	0,5065	0,0203
Validation	0,4586	0,5404	0,4991	0,0158
Testing	0,4394	0,5457	0,4847	0,0231

Model CNN 1D pada representasi *Raw Time Series* dalam Tabel 5 menghasilkan probabilitas prediksi pada data latih dalam rentang 0,4426–0,5599 dengan rata-rata 0,5065. Pada data validasi, probabilitas berada pada rentang 0,4586–0,5404 dengan rata-rata 0,4991, sedangkan pada data pengujian berada pada rentang 0,4394–0,5457 dengan rata-rata 0,4847. Rata-rata probabilitas pada data pengujian yang berada di bawah 0,5 menunjukkan bahwa keluaran model secara rata-rata cenderung berada di bawah batas klasifikasi standar. Namun, kondisi ini belum cukup untuk menentukan kemampuan model dalam mengklasifikasikan kedua kelas karena hasil klasifikasi juga bergantung pada distribusi probabilitas dan nilai *threshold* yang digunakan.

Tabel 6 Distribusi Probabilitas Prediksi Model *Hybrid* CNN-LSTM 1D Raw *Time Series*

Jenis Data	Minimum	Maksimum	Mean	Std
Training	0,5037	0,5587	0,5228	0,0098
Validation	0,5134	0,5636	0,5318	0,0108
Testing	0,5188	0,5850	0,5489	0,0131

Pada model *Hybrid* CNN-LSTM dengan representasi *Raw Time Series* dalam Tabel 6, rata-rata probabilitas prediksi pada data latih, validasi, dan pengujian masing-masing sebesar 0,5228, 0,5318, dan 0,5489. Probabilitas pada data pengujian berada pada rentang 0,5188–0,5850. Seluruh nilai probabilitas tersebut berada di atas *threshold* standar 0,5, sehingga seluruh observasi pengujian diprediksi sebagai kelas 1 (Naik). Kondisi ini menunjukkan bahwa model belum mampu mengenali kelas 0 (Turun/Tidak Naik) pada batas klasifikasi tersebut, meskipun menghasilkan *recall* yang tinggi untuk kelas 1.

Tabel 7 Distribusi Probabilitas Prediksi Model LSTM GASF

Jenis Data	Minimum	Maksimum	Mean	Std
Training	0,4105	0,7179	0,5651	0,0484
Validation	0,4114	0,7056	0,5708	0,0458
Testing	0,4088	0,7048	0,5679	0,0471

Pada representasi GASF, model LSTM dalam tabel 7 menghasilkan rata-rata probabilitas sebesar 0,5651 pada data latih, 0,5708 pada data validasi, dan 0,5679 pada data pengujian. Probabilitas pada data pengujian berada pada rentang 0,4088–0,7048 dengan simpangan baku 0,0471. Dibandingkan model LSTM pada representasi *Raw Time Series*, rentang probabilitas LSTM GASF lebih lebar. Hal ini menunjukkan bahwa keluaran probabilitasnya lebih bervariasi, tetapi belum dapat diartikan sebagai peningkatan kemampuan klasifikasi karena ketepatan prediksi tetap perlu dinilai berdasarkan kelas aktual dan metrik evaluasi.

.

Tabel 8 Distribusi Probabilitas Prediksi Model CNN 2D GASF

Jenis Data	Minimum	Maksimum	Mean	Std
Training	0,2455	0,8471	0,5408	0,0848
Validation	0,3261	0,7379	0,5367	0,0758
Testing	0,3183	0,7608	0,5255	0,0749

Model CNN 2D pada representasi GASF dalam Tabel 8 menghasilkan rata-rata probabilitas sebesar 0,5408 pada data latih, 0,5367 pada data validasi, dan 0,5255 pada data pengujian. Pada data pengujian, probabilitas berada pada rentang 0,3183–0,7608 dengan simpangan baku 0,0749. Rentang tersebut menunjukkan variasi probabilitas yang lebih lebar dibandingkan CNN 1D pada representasi *Raw Time Series*. Probabilitas yang berada di bawah dan di atas 0,5 memungkinkan model menghasilkan prediksi untuk kedua kelas pada batas klasifikasi standar. Namun, kemampuan model dalam mengenali kedua kelas tetap perlu dinilai berdasarkan *confusion matrix* dan metrik evaluasi.

Tabel 9 Distribusi Probabilitas Prediksi Model *Hybrid* CNN-LSTM GASF

Jenis Data	Minimum	Maksimum	Mean	Std
Training	0,4189	0,7793	0,5937	0,0639
Validation	0,4269	0,7779	0,5934	0,0582
Testing	0,4284	0,7385	0,5934	0,0549

Model *Hybrid* CNN-LSTM pada representasi GASF dalam Tabel 9 menghasilkan rata-rata probabilitas sebesar 0,5937 pada data latih serta 0,5934 pada data validasi dan pengujian. Pada data pengujian, probabilitas berada pada rentang 0,4284–0,7385 dengan simpangan baku 0,0549. Meskipun rata-rata probabilitas berada di atas 0,5, terdapat nilai probabilitas di bawah

batas tersebut. Dengan demikian, tidak seluruh observasi pengujian diprediksi sebagai kelas 1 pada *threshold* standar 0,5. Hal ini berbeda dari model *Hybrid* CNN-LSTM pada representasi *Raw Time Series*, yang seluruh probabilitas pengujiannya berada di atas 0,5.

Probabilitas prediksi setiap model dikonversi menjadi kelas menggunakan dua pendekatan, yaitu *threshold* standar sebesar 0,5 dan *threshold* optimal. *Threshold* 0,5 digunakan sebagai batas klasifikasi standar, sedangkan *threshold* optimal digunakan untuk mengevaluasi apakah penyesuaian batas keputusan dapat meningkatkan keseimbangan pengenalan kelas Naik dan Tidak Naik. Nilai *threshold* optimal ditentukan berdasarkan *Balanced Accuracy* tertinggi pada data validasi melalui pencarian pada rentang 0 hingga 1 dengan interval 0,001. Nilai yang diperoleh kemudian diterapkan pada data pengujian tanpa melakukan optimasi ulang pada data tersebut. Prosedur ini memungkinkan perbandingan kinerja kedua pendekatan sekaligus menjaga pemisahan antara proses pemilihan *threshold* dan evaluasi akhir model. Penggunaan *Balanced Accuracy* sebagai kriteria pemilihan juga mempertimbangkan kemampuan model dalam mengenali kedua kelas, sehingga keputusan tidak hanya didasarkan pada ketepatan prediksi secara keseluruhan.

Tabel 10 Hasil Confusion Matrix dengan *Threshold* 0,5

Model	TN	FP	FN	TP
LSTM *Raw*	21	178	29	260
CNN 1D *Raw*	152	47	235	54
Hybrid CNN-LSTM *Raw*	0	199	0	289
LSTM GASF	12	187	25	264
CNN 2D GASF	76	123	110	179
Hybrid CNN-LSTM GASF	7	192	9	280

Berdasarkan Tabel 10, model *Hybrid* CNN-LSTM *Raw Time Series* memprediksi seluruh data pengujian sebagai kelas Naik. Hal ini ditunjukkan oleh nilai TN dan FN yang sama-sama bernilai 0, sehingga model tidak berhasil mengenali kelas Tidak Naik. Pada model *Hybrid* CNN-LSTM GASF, sebanyak 280 data kelas Naik diklasifikasikan dengan benar, sedangkan hanya 7 data kelas Tidak Naik yang dikenali dengan benar. Hasil tersebut menunjukkan bahwa penggunaan *threshold* 0,5 menghasilkan kecenderungan prediksi terhadap kelas Naik pada kedua model hibrida, meskipun tingkat pengenalan kelas Tidak Naik berbeda.

Tabel 11 Hasil *Confusion Matrix* dengan *Threshold* Optimal

Model	*Threshold*	TN	FP	FN	TP
LSTM *Raw*	0,5720	196	3	282	7
CNN 1D *Raw*	0,5300	185	14	274	15
Hybrid CNN-LSTM *Raw*	0,5340	26	173	38	251
LSTM GASF	0,5220	29	170	50	239
CNN 2D GASF	0,6020	172	27	246	43
Hybrid CNN-LSTM GASF	0,6100	128	71	171	118

Berdasarkan Tabel 11, penerapan *threshold* optimal mengubah pola prediksi keenam model. Pada *Hybrid* CNN-LSTM GASF, *threshold* 0,610 menghasilkan 128 prediksi benar untuk kelas Tidak Naik dan 118 prediksi benar untuk kelas Naik. Sebanyak 71 data kelas Tidak Naik masih diprediksi sebagai Naik, sedangkan 171 data kelas Naik diprediksi sebagai Tidak Naik. Dibandingkan penggunaan *threshold* 0,5, jumlah prediksi benar untuk kelas Tidak Naik meningkat dari 7 menjadi 128, sedangkan jumlah prediksi benar untuk kelas Naik menurun dari 280 menjadi 118. Perubahan ini memperlihatkan bahwa penyesuaian *threshold* mengubah

keseimbangan prediksi antara kedua kelas, tetapi tidak selalu meningkatkan jumlah prediksi benar secara keseluruhan.

Evaluasi kinerja model dilakukan menggunakan *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Balanced Accuracy*. *Balanced Accuracy* digunakan sebagai acuan utama karena mempertimbangkan kemampuan model dalam mengenali kedua kelas. Dengan demikian, model yang cenderung memprediksi satu kelas tidak langsung dinilai baik hanya karena memperoleh *Accuracy* atau *Recall* yang tinggi pada kelas tersebut.

Tabel 12 Hasil Evaluasi Model dengan *Threshold* 0,5

Model	*Accuracy*	*Precision*	*Recall*	F1-*Score*	BA
LSTM *Raw*	57,58%	59,36%	89,97%	71,53%	50,26%
CNN 1D *Raw*	42,21%	53,47%	18,69%	27,69%	47,53%
Hybrid CNN-LSTM *Raw*	59,22%	59,22%	100,00%	74,39%	50,00%
LSTM GASF	56,56%	58,54%	91,35%	71,35%	48,69%
CNN 2D GASF	52,25%	59,27%	61,94%	60,58%	50,06%
Hybrid CNN-LSTM GASF	58,81%	59,32%	96,89%	73,59%	50,20%

Berdasarkan Tabel 12, *Hybrid* CNN-LSTM *Raw Time Series* memperoleh *Accuracy* tertinggi sebesar 59,22% dan *Recall* sebesar 100,00%. Namun, *Balanced Accuracy* model tersebut hanya 50,00% karena seluruh data uji diprediksi sebagai kelas Naik. LSTM *Raw Time Series* memperoleh *Accuracy* sebesar 57,58% dengan *Balanced Accuracy* sebesar 50,26%. Sementara itu, CNN 1D *Raw Time Series* menghasilkan *Balanced Accuracy* sebesar 47,53%, lebih rendah daripada CNN 2D GASF yang mencapai 50,06%. Perbandingan ini menunjukkan bahwa *Accuracy* dan *Recall* yang tinggi tidak selalu mencerminkan kemampuan yang seimbang dalam mengenali kelas Tidak Naik dan Naik.

Tabel 13 Hasil Evaluasi Model dengan *Threshold* Optimal

Model	*Threshold*	ACC	*Precision*	*Recall*	F1-*Score*	BA
LSTM *Raw*	0,5720	41,60%	70,00%	2,42%	4,68%	50,46%
CNN 1D *Raw*	0,5300	40,98%	51,72%	5,19%	9,43%	49,08%
Hybrid CNN-LSTM *Raw*	0,5340	56,76%	59,20%	86,85%	70,41%	49,96%
LSTM GASF	0,5220	54,92%	58,44%	82,70%	68,48%	48,64%
CNN 2D GASF	0,6020	44,06%	61,43%	14,88%	23,96%	50,66%
***Hybrid* CNN-LSTM GASF**	**0,6100**	**50,41%**	**62,43%**	**40,83%**	**49,37%**	**52,58%**

Berdasarkan Tabel 13, *Hybrid* CNN-LSTM GASF memperoleh *Balanced Accuracy* tertinggi sebesar 52,58% dengan *threshold* 0,610, diikuti CNN 2D GASF sebesar 50,66%, LSTM *Raw Time Series* sebesar 50,46%, *Hybrid* CNN-LSTM *Raw Time Series* sebesar 49,96%, CNN 1D *Raw Time Series* sebesar 49,08%, dan LSTM GASF sebesar 48,64%. Hasil tersebut menunjukkan bahwa *Hybrid* CNN-LSTM GASF menghasilkan keseimbangan pengenalan kedua kelas terbaik di antara enam skenario yang diuji. Meskipun demikian, nilai *Balanced Accuracy* sebesar 52,58% masih relatif dekat dengan 50%, sehingga kemampuan klasifikasi model secara keseluruhan masih terbatas.

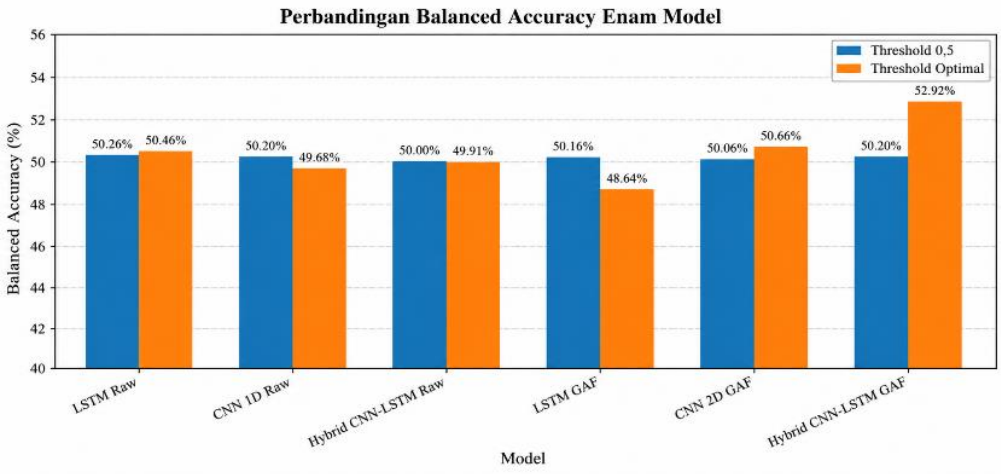

Gambar 3 Perbandingan Enam Model

Berdasarkan Gambar 3, penyesuaian *threshold* tidak selalu meningkatkan seluruh metrik evaluasi secara bersamaan. Pada model *Hybrid* CNN-LSTM GASF, *Balanced Accuracy* meningkat dari 50,20% pada *threshold* 0,5 menjadi 52,58% pada *threshold* optimal 0,610. Namun, *Accuracy* menurun dari 58,81% menjadi 50,41%. Perubahan tersebut menunjukkan bahwa penyesuaian *threshold* dapat memperbaiki keseimbangan pengenalan kelas Naik dan Tidak Naik tanpa harus meningkatkan jumlah prediksi benar secara keseluruhan. Hal serupa terlihat pada LSTM *Raw*, yang memperoleh *Balanced Accuracy* sebesar 50,46% pada *threshold* optimal 0,5720, tetapi hanya memiliki *Recall* sebesar 2,42%. Artinya, model hanya berhasil mengenali 7 dari 289 data aktual kelas Naik. Temuan ini memperlihatkan bahwa penilaian kinerja model perlu mempertimbangkan beberapa metrik sekaligus sesuai dengan tujuan klasifikasi.

Perbandingan *Balanced Accuracy* pada *threshold* optimal antara representasi *Raw Time Series* dan GASF menunjukkan hasil yang berbeda pada setiap arsitektur. Pada LSTM, *Balanced Accuracy* menurun dari 50,46% pada *Raw Time Series* menjadi 48,64% pada GASF, atau turun sebesar 1,82 poin persentase. Sebaliknya, pada CNN, nilainya meningkat dari 49,08% menjadi 50,66%, atau naik sebesar 1,58 poin persentase. Peningkatan lebih besar terlihat pada *Hybrid* CNN-LSTM, dari 49,96% menjadi 52,58%, atau sebesar 2,62 poin persentase. Hasil ini menunjukkan bahwa GASF tidak menghasilkan peningkatan kinerja yang konsisten pada seluruh arsitektur. Dalam eksperimen ini, representasi GAF berkaitan dengan nilai *Balanced Accuracy* yang lebih tinggi pada CNN dan *Hybrid* CNN-LSTM, tetapi lebih rendah pada LSTM.

Perbedaan tersebut dapat ditinjau dari karakteristik representasi data dan mekanisme pemrosesan setiap arsitektur. Pada *Raw Time Series*, data disajikan sebagai urutan nilai fitur dari waktu ke waktu. Sebaliknya, GASF mengubah urutan tersebut menjadi matriks dua dimensi yang merepresentasikan hubungan antarwaktu melalui transformasi sudut. Representasi ini memungkinkan pola deret waktu disajikan dalam bentuk spasial yang dapat diproses menggunakan operasi konvolusi dua dimensi. Pada CNN 2D GASF, operasi konvolusi berpotensi membantu model mengenali pola lokal dan hubungan antarelemen dalam matriks. Hal ini dapat menjadi salah satu kemungkinan penjelasan atas peningkatan *Balanced Accuracy* dari 49,08% menjadi 50,66%. Namun, peningkatan tersebut relatif kecil dan belum menunjukkan kemampuan klasifikasi yang kuat.

Pada *Hybrid* CNN-LSTM GASF, CNN digunakan untuk mengekstraksi fitur dari representasi citra, kemudian LSTM memproses urutan fitur untuk mempelajari ketergantungan temporal. Penggabungan kedua mekanisme tersebut berpotensi membantu model memanfaatkan pola spasial sekaligus informasi urutan waktu. Hasil eksperimen menunjukkan bahwa *Balanced Accuracy* model ini meningkat sebesar 2,62 poin persentase dibandingkan versi *Raw Time Series*. Namun, nilai *Balanced Accuracy* sebesar 52,58% masih menunjukkan kemampuan klasifikasi yang terbatas. Oleh karena itu, hasil tersebut lebih tepat dipandang sebagai indikasi bahwa

kombinasi arsitektur dan representasi GASF memberikan hasil yang relatif lebih baik dalam eksperimen ini, bukan sebagai bukti langsung bahwa model berhasil mempelajari pola spasial dan temporal tertentu.

Berbeda dengan kedua arsitektur tersebut, LSTM menghasilkan *Balanced Accuracy* yang lebih rendah ketika menggunakan GASF, yaitu dari 50,46% menjadi 48,64%. Salah satu kemungkinan penjelasannya adalah perbedaan struktur masukan yang diproses oleh model. Pada *Raw Time Series*, LSTM menerima urutan nilai fitur secara langsung, sehingga informasi temporal disajikan dalam bentuk sekuens. Pada GASF, hubungan antarwaktu direpresentasikan melalui matriks dua dimensi yang kemudian disusun menjadi masukan bagi LSTM. Perubahan bentuk masukan ini dapat mengubah cara informasi disajikan kepada model dan tidak secara otomatis menjamin bahwa ketergantungan temporal akan dipelajari dengan lebih baik. Namun, penyebab penurunan tersebut belum dapat dipastikan hanya dari nilai metrik evaluasi karena konfigurasi model, proses pelatihan, dan karakteristik fitur juga dapat berperan.

Secara keseluruhan, *Hybrid* CNN-LSTM GASF memperoleh *Balanced Accuracy* tertinggi sebesar 52,58% pada *threshold* optimal 0,610 di antara enam skenario yang diuji. Nilai tersebut lebih tinggi 2,62 poin persentase dibandingkan *Hybrid* CNN-LSTM *Raw Time Series*. Meskipun demikian, nilai *Balanced Accuracy* yang masih relatif dekat dengan 50% menunjukkan bahwa kemampuan model dalam membedakan kedua kelas belum kuat. Temuan utama penelitian ini adalah bahwa hasil penggunaan GASF bergantung pada arsitektur yang digunakan. Representasi GASF berkaitan dengan peningkatan *Balanced Accuracy* pada CNN dan *Hybrid* CNN-LSTM, tetapi penurunan pada LSTM. Dengan demikian, representasi berbasis citra perlu dievaluasi bersama arsitektur model dan tidak dapat diasumsikan selalu menghasilkan kinerja klasifikasi yang lebih baik.

4. KESIMPULAN

Berdasarkan hasil penelitian, model *Hybrid* CNN-LSTM dengan representasi *Gramian Angular Summation Field* (GASF) memperoleh *Balanced Accuracy* tertinggi sebesar 52,58% di antara enam skenario yang dievaluasi, dengan *threshold* optimal sebesar 0,610. Nilai tersebut lebih tinggi 2,62 poin persentase dibandingkan representasi *Raw Time Series* pada arsitektur yang sama, yaitu 49,96%. Meskipun memperoleh kinerja tertinggi, nilai *Balanced Accuracy* yang masih mendekati 50% menunjukkan bahwa kemampuan klasifikasi model dalam membedakan arah pergerakan harga emas masih terbatas. Perbandingan ketiga arsitektur menunjukkan bahwa GASF tidak menghasilkan peningkatan kinerja yang konsisten. Pada LSTM, *Balanced Accuracy* menurun dari 50,46% pada representasi *Raw Time Series* menjadi 48,64% pada GASF. Sebaliknya, pada CNN, nilainya meningkat dari 49,08% menjadi 50,66%, sedangkan pada *Hybrid* CNN-LSTM meningkat dari 49,96% menjadi 52,58%. Penelitian selanjutnya disarankan mengevaluasi variasi ukuran *sliding window*, konfigurasi arsitektur, dan parameter pelatihan untuk mengetahui konfigurasi yang lebih sesuai dengan karakteristik data. Pengujian pada periode waktu yang berbeda juga diperlukan untuk mengevaluasi kestabilan kinerja model. Selain itu, penggunaan variabel eksternal dan representasi deret waktu alternatif dapat dieksplorasi untuk mengetahui apakah informasi tambahan dan pendekatan representasi yang berbeda dapat menghasilkan kemampuan klasifikasi yang lebih baik. Evaluasi selanjutnya juga perlu mempertimbangkan keseimbangan pengenalan kedua kelas, mengingat nilai *Balanced Accuracy* pada penelitian ini masih relatif dekat dengan 50%.

5. ACKNOWLEDGEMENTS

Penulis menyampaikan terima kasih kepada Universitas Negeri Surabaya, Program Studi S1 Sistem Informasi, serta pihak-pihak yang telah memberikan dukungan, masukan, dan bantuan selama proses penelitian dan penyusunan artikel ini.

REFERENSI

[1] A. F. Yuliana and R. Robiyanto, "PERAN EMAS SEBAGAI SAFE HAVEN BAGI SAHAM PERTAMBANGAN DI INDONESIA PADA PERIODE PANDEMI COVID-19," *Jurnal Ilmiah Bisnis Dan Ekonomi Asia*, vol. 15, No. 1, 2021, pp. 1–11. https://doi.org/10.32815/jibeka.v15i1.217

[2] T. A. Setiyono, H. Ghassani, and S. Dewi, "Determinan COVID-19 terhadap harga emas," *Jurnal STIE Semarang*, vol. 14, no. 1, pp. 107–116, Feb. 2022. [Online]. Available: https://www.jurnal3.stiesemarang.ac.id/index.php/jurnal/article/view/538

[3] I. Yousef and E. Shehadeh, "The Impact of COVID-19 on Gold Price Volatility," *International Journal of Economics and Business Administration*, vol. *VIII, No.* 4, 2020, pp. 353–364.

[4] P. S. M. J. Silaban, P. D. Putra, E. Dilani, and K. P. Simbolon, "Analisis dan strategi uang beredar, tingkat suku bunga dan nilai tukar terhadap inflasi akibat COVID-19 di Indonesia," *Prosiding Webinar Fakultas Ekonomi Unimed: Strategi Dunia Usaha Menyikapi Status Indonesia Sebagai Negara Maju: Pra dan Pasca COVID-19*, 2020, pp. 74–85. [Online]. Available: https://digilib.unimed.ac.id/id/eprint/40560/

[5] D. Magfiroh and K. Komarudin, "Melambungnya harga emas di tengah ketegangan geopolitik dan tekanan inflasi global," *Lentera: Multidisciplinary Studies*, vol. 3, no. 3, 2025. doi: 10.57096/lentera.v3i3.165.

[6] S.P. Kennedy, "DAMPAK PERANG RUSIA-UKRAINA TERHADAP PEREKONOMIAN GLOBAL," *Fundamental Management Journal*, 2023, pp. 1–12. https://doi.org/10.33541/fjm.v8i2p.5265

[7] S. Sopiyah, L. Safitri, A. Rodiyah, E. N. Anisah, Sundana, H., and A.Afandi, "Pengaruh Harga Emas Dunia, Harga Minyak Dunia Dan Indeks Dow Jones (DJIA) Terhadap Indeks Harga Saham Gabungan Di Indonesia Pada Periode Perang Dagang AS-Tiongkok," *PARADOKS Jurnal Ilmu Ekonomi*, vol. *8 No.* 3, 2025. https://doi.org/10.57178/paradoks.v8i3.1377.

[8] H. Zhang, R. Demirer, J. Huang, W. Huang, and M. T. Suleman, "Economic policy uncertainty and gold return dynamics: Evidence from high-frequency data," *Resources Policy*, vol. 72, 2021. https://doi.org/10.1016/j.resourpol.2021.102078.

[9] I. Shaikh and P. Vallabh, "Monetary policy uncertainty and gold price in India: Evidence from Reserve Bank of India's Monetary Policy Committee (MPC) review," *Resources Policy*, vol. 76, 2022. https://doi.org/10.1016/j.resourpol.2022.102642

[10] Melina, Sukono, H. Napitupulu, N. Mohamed, Y. H. Chrisnanto, A. I. D. Hadiana, V. A. Kusumaningtyas, and U. Nabilla, "COMPARATIVE ANALYSIS OF *TIME SERIES* FORECASTING MODELS USING ARIMA AND NEURAL NETWORK AUTOREGRESSION METHODS," *Barekeng*, vol. 18, No. 4, 2024, pp. 2563–2576. https://doi.org/10.30598/barekengvol18iss4pp2563-2576

[11] S. R.Masud, A. Imtiaz, S. M. Hossain, and M. S. U. Miah, "A Comprehensive Approach to Gold Price Prediction Using Machine Learning and *Time series* Models," *2025 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation, IATMSI 2025*, 2025. https://doi.org/10.1109/IATMSI64286.2025.10984927

[12] K. M. J. Tarnate, M. Devaraj, and J. C. De Goma, "Overcoming The Vanishing Gradient Problem Of Recurrent Neural Networks In The Iso 9001 Quality Management Audit Reports Classification," *INTERNATIONAL JOURNAL OF SCIENTIFIC & TECHNOLOGY RESEARCH*, vol. 9, No. 3, 2020. www.ijstr.org

[13] N. A. Burhani, D. Saepudin, and D. Adytia, "Prediksi Return Saham Berdasarkan Data Histori dan Data Fundamental Menggunakan LSTM," *Jurnal Penelitian Informatika*, vol. 3, 2025, pp. 27–32. https://doi.org/10.25124/logic.v3i1.6467

[14] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU," *Jurnal Informatika Dan Teknik Elektro Terapan*, vol. 11, No. 3, 2023. https://doi.org/10.23960/jitet.v11i3.3250

[15] M. A. Irwansyah, A. Triana, Simanullang, E. D., Alinda, Y. N., and A. Ibrahim, "PREDIKSI HARGA DAN VOLATILITAS EMAS DUNIA HARIAN: PERBANDINGAN MODEL GARCH DAN LONG SHORT-TERM MEMORY. *Jurnal Sistem Informasi*, Vol. 7, No. 2, 2025.

[16] M. Gholipour, "*Leveraging the Power of Hybrid Models: Combining ARIMA and LSTM for Accurate Bitcoin Price Forecasting*. M.S. thesis, Department of Computer Science, Bishop's University, Canada, 2023. [Online]. Available: https://www.ubishops.ca/wp-content/uploads/gholipour20230905.pdf

[17] A. P. Wibawa, A. B. P. Utama, H. Elmunsyah, U. Pujianto, F. A. Dwiyanto, and L. Hernandez, "Time-series analysis with smoothed Convolutional Neural Network. *Journal of Big Data*, vol. *9*, No. 1, 2022. https://doi.org/10.1186/s40537-022-00599-y

[18] R. Zahilah, S. Hajar, and D. Setiawan, "CNN–LSTM *Hybrid* Model for Improving Bitcoin Price Prediction Results," *Applied Mathematics and Computational Intelligence*, vol. 12, No. 4, 2023. https://doi.org/10.58915/amci.v12i4.349

[19] J. Li, "The comparison of LSTM, LGBM, and CNN in stock volatility prediction," in *Proceedings of the 2022 7th International Conference on Financial Innovation and Economic Development (ICFIED 2022)*, *Advances in Economics, Business and Management Research*. Atlantis Press, 2022, pp. 905–909. doi: 10.2991/aebmr.k.220307.147.

[20] H. Widiputra, A. Mailangkay, and E. Gautama, "Multivariate CNN–LSTM Model for Multiple Parallel Financial Time-Series Prediction," *Complexity*, 2021. https://doi.org/10.1155/2021/9903518

[21] S. Barra, S. M. Carta, A. Corriga, A. S. Podda, and D. R. Recupero, "*Deep learning* and *time series*-To-image encoding for financial forecasting," *IEEE/CAA Journal of Automatica Sinica*, vol. 7, No. 3, 2020, pp. 683–692. https://doi.org/10.1109/JAS.2020.1003132

[22] J. Wu, Z. Zhang, R. Tong, Y. Zhou, Z. Hu, and K. Liu, "Imaging feature-based clustering of financial *time series*," *PLoS ONE*, vol. 18, 2023. https://doi.org/10.1371/journal.pone.0288836

[23] M. Mariani, P. Appiah, and O. Tweneboah, "Fusion of Recurrence Plots and Gramian Angular Fields with Bayesian Optimization for Enhanced Time-Series Classification," *Axioms*, vol. 14. No. 7, 2025, pp. 528. https://doi.org/10.3390/axioms14070528

[24] Z. Wang and T. Oates, "Encoding time series as images for visual inspection and classification using tiled convolutional neural networks," in *Proceedings of the Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence*, *Trajectory-Based Behavior Analytics: Papers from the 2015 AAAI Workshop*. AAAI Press, 2015. [Online]. Available: https://cdn.aaai.org/ocs/ws/ws0115/10179-46015-1-PB.pdf