

IMPLEMENTASI TCN BERBASIS IDENTIFIKASI REGIME PASAR DENGAN HMM UNTUK PREDIKSI HARGA EMAS

Febriana Susilowati¹, Dedy Kurniadi²

^{1,2}Universitas Islam Sultan Agung

¹febriana182@gmail.com, ²ddy.kurniadi@unissula.ac.id

Received: 03-06-2026

Revised: 10-06-2026

Approved: 22-06-2026

ABSTRAK

Penelitian ini bertujuan untuk membangun model prediksi harga emas ANTAM yang adaptif terhadap perubahan kondisi pasar melalui integrasi Hidden Markov Model (HMM) untuk identifikasi market regime dan Temporal Convolutional Network (TCN) untuk pemodelan deret waktu. Metode penelitian yang digunakan adalah pendekatan kuantitatif dengan memanfaatkan data historis harga emas ANTAM periode 2019–2025 sebanyak 1.450 observasi yang diperoleh dari Kaggle. Data diproses melalui tahapan preprocessing, perhitungan log return, identifikasi market regime menggunakan HMM, pemodelan prediksi menggunakan TCN, serta evaluasi menggunakan metrik Mean Absolute Error (MAE) dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa HMM berhasil mengidentifikasi dua rezim pasar dominan, yaitu bearish dan volatile, yang kemudian digunakan sebagai fitur tambahan pada model TCN. Integrasi kedua metode menghasilkan performa prediksi yang lebih baik dibandingkan model TCN standar, dengan nilai MAE sebesar 70,74 dan MAPE sebesar 4,80%, lebih rendah dibandingkan TCN standar yang memperoleh MAE 92,15 dan MAPE 5,90%. Selain itu, hasil prediksi lima hari ke depan menunjukkan kecenderungan kenaikan harga emas secara bertahap dan stabil. Simpulan penelitian ini adalah bahwa integrasi HMM dan TCN mampu meningkatkan akurasi prediksi harga emas dengan mengakomodasi perubahan rezim pasar secara lebih adaptif, sehingga menghasilkan model prediksi yang lebih tangguh dan efektif untuk mendukung pengambilan keputusan investasi.

Kata Kunci : Gold Price Prediction; Hidden Markov Model; Market Regime; Temporal Convolutional Network; Time Series Forecasting

PENDAHULUAN

Emas diakui secara global sebagai instrumen investasi aman (safe-haven asset) dan alat lindung nilai (hedging) utama terhadap inflasi serta ketidakpastian geopolitik (Taneva-Angelova et al., 2025). Dinamika fluktuasi harganya menjadi indikator krusial bagi investor, institusi keuangan, dan pembuat kebijakan dalam mengelola risiko portofolio. Di pasar domestik, emas produksi PT Aneka Tambang Tbk (ANTAM) menjadi pilihan investasi utama berkat fitur keamanan kemasan CertiCard serta akreditasi dari London Bullion Market Association (LBMA) yang menjamin keaslian dan kemurniannya (Amri et al., 2024). Oleh karena itu, akurasi prediksi harga emas ANTAM menjadi sangat urgen demi menjaga stabilitas portofolio investor lokal. Namun, pergerakan harga aset ini di pasar finansial dicirikan oleh sifatnya yang non-linear, non-stasioner, dan memiliki tingkat volatilitas yang tinggi. Perubahan tren yang mendadak akibat interaksi kompleks berbagai faktor makroekonomi ini membuat proses peramalan menjadi sangat menantang.

Pada awalnya, pemodelan deret waktu tradisional kerap digunakan untuk memproyeksikan pergerakan aset ini. Beberapa studi terdahulu memanfaatkan metode statistik konvensional seperti regresi linear historis (Cahya & Chaidir, 2025), pemulusan tren linier Holt (Tengger & Reviladi, 2025), hingga analisis volatilitas berbasis GARCH (Amri et al., 2024). Pendekatan tersebut memang efektif untuk menangkap tren jangka pendek yang bersifat linear. Kendati demikian, model statistik klasik ini sering kali kehilangan akurasinya saat dihadapkan pada fluktuasi harga ekstrem akibat guncangan pasar atau pergeseran struktural yang drastis. Untuk mengatasi keterbatasan model linear konvensional, tren riset

mutakhir mulai didominasi oleh implementasi algoritma kecerdasan buatan (Artificial Intelligence). Pendekatan machine learning, seperti kombinasi regresi linear dengan K-Nearest Neighbors (KNN), sempat diterapkan untuk memetakan pola historis (Martin et al., 2025). Sayangnya, algoritma berbasis kedekatan tetangga ini kurang optimal dalam menangkap karakteristik mendalam dari data deret waktu finansial. Sebagai alternatif, arsitektur deep learning seperti Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) mulai diandalkan karena kemampuannya mengekstraksi fitur nonlinear yang rumit, baik dari data deret waktu emas global maupun domestik (Tholib et al., 2023; Nafie et al., 2025). Meskipun model Recurrent Neural Network (RNN) seperti LSTM dan GRU menawarkan akurasi tinggi, model-model ini memiliki kelemahan bawaan berupa proses komputasi yang bersifat sekuensial.

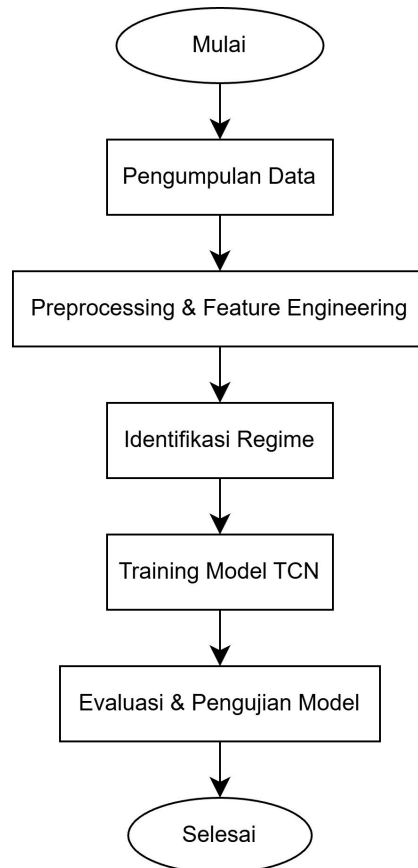
Keterbatasan ini menyebabkan pelatihan model memerlukan waktu yang lama pada dataset berskala besar serta rentan terhadap kendala hilangnya gradien (vanishing gradient) pada dependensi temporal jangka panjang. Sebagai solusinya, Temporal Convolutional Network (TCN) hadir sebagai arsitektur mutakhir yang memanfaatkan konvolusi kausal dilasi (dilated causal convolutions). TCN terbukti lebih unggul daripada LSTM dalam menangkap pola temporal jangka panjang secara paralel, stabil, dan efisien (Marscelina et al., 2025). Keunggulan TCN ini telah berhasil diuji pada berbagai instrumen investasi dengan volatilitas tinggi, termasuk prediksi aset kripto (Munandar, 2025) maupun peramalan harga saham terintegrasi (Teck & Thenata, 2025). Namun, meskipun memiliki kemampuan representasi temporal yang superior, TCN kerap mengalami penurunan performa jika dilatih secara homogen pada data yang mengalami transisi struktural atau pergeseran rezim pasar (market regime switching), seperti fase bullish, bearish, atau volatile. Fluktuasi pasar keuangan tidak bergerak dalam satu kondisi statis, melainkan terus berpindah antar-kondisi laten yang dipengaruhi oleh sentimen ekonomi. Untuk menjembatani celah tersebut, identifikasi rezim pasar menggunakan Hidden Markov Model (HMM) menjadi langkah yang krusial. Didukung oleh algoritma komplementer seperti Viterbi (Purnama et al., 2023) atau sistem Markov Chain (Putri et al., 2025), HMM terbukti andal dalam mendeteksi dan mengelompokkan status tersembunyi (hidden states) dari data observasi imbal hasil (return) pasar keuangan.

Beberapa pengembangan model hibrida sejenis sebelumnya telah mencoba mengintegrasikan pembagian data berbasis rezim, seperti kombinasi ARIMAX-GARCH yang andal pada fluktuasi linear bermotif khusus atau hibrida HMM-LSTM yang mampu menangkap memori jangka panjang pasca-segmentasi rezim (Tampouris & Dritsaki, 2026). Kendati demikian, model hibrida berbasis RNN tersebut masih terhambat oleh inefisiensi komputasi sekuensial serta risiko overfitting saat menghadapi transisi rezim yang bergerak cepat. Berdasarkan kesenjangan riset tersebut, penelitian ini mengusulkan sebuah model hibrida baru, yaitu Temporal Convolutional Network (TCN) berbasis Identifikasi Rezim Pasar dengan Hidden Markov Model (HMM) untuk prediksi harga emas. Melalui integrasi ini, HMM bertindak di hulu untuk mengidentifikasi dan mengklasifikasikan rezim pasar secara adaptif, sementara arsitektur TCN di hilir dilatih secara spesifik sesuai dengan karakteristik temporal dari masing-masing rezim yang terdeteksi. Pendekatan hibrida ini diharapkan mampu meningkatkan akurasi peramalan secara signifikan, menekan nilai Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE), serta menghasilkan model prediksi harga emas yang tangguh terhadap perubahan struktural pasar finansial global maupun domestik.

METODE PENELITIAN

Penelitian ini bertujuan untuk membangun model prediksi harga emas dengan

mengintegrasikan *Hidden Markov Model* (HMM) untuk identifikasi *market regime* dan *Temporal Convolutional Network* (TCN) untuk pemodelan data deret waktu. Tahapan penelitian yang dilakukan meliputi pengumpulan data, *preprocessing* dan *feature engineering*, identifikasi *market regime*, pemodelan TCN, serta evaluasi model.



Gambar 1. Tahap penelitian

1. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data historis harga emas ANTAM dengan frekuensi harian yang diperoleh dari platform Kaggle. Dataset mencakup periode tahun 2019 hingga 2025 dengan total 1.450 observasi. Variabel yang digunakan meliputi *price*, *open*, *high*, *low*, dan *volume*. Data tersebut dipilih karena mampu merepresentasikan berbagai kondisi pasar riil, termasuk periode pandemi COVID-19, masa pemulihan ekonomi, dan kondisi tren terkini, sehingga model dapat mempelajari pola pergerakan harga dalam situasi pasar yang beragam.

2. Preprocessing dan Feature Engineering

Tahap preprocessing dilakukan untuk memastikan data siap digunakan dalam proses pelatihan model. Proses ini meliputi:

- Mengubah nama kolom menjadi huruf kecil untuk menjaga konsistensi data.
- Mengonversi kolom *date* ke format *datetime*.
- Membersihkan data numerik dari tanda koma dan mengubah tipe data menjadi *float*.
- Mengurutkan data berdasarkan waktu secara kronologis.

Setelah proses pembersihan data, dilakukan *feature engineering* dengan

menghitung nilai *log return* untuk merepresentasikan perubahan harga relatif antar-periode. Perhitungan *log return* dilakukan menggunakan persamaan berikut:

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad (1)$$

dengan:

r_t = log return pada waktu ke-t

P_t = harga pada waktu ke-t

P_{t-1} = harga pada waktu sebelumnya

Penggunaan *log return* bertujuan untuk menstabilkan varians data dan mempermudah model dalam mengenali pola perubahan harga pada deret waktu finansial.

3. Identifikasi Market Regime Menggunakan HMM

Identifikasi kondisi pasar dilakukan menggunakan *Hidden Markov Model* (HMM). Model dikonfigurasi dengan tiga *hidden states* yang merepresentasikan tiga kondisi pasar secara intuitif, yaitu *bullish*, *bearish*, dan *volatile*.

Secara matematis, karakteristik stokastik dari HMM ditentukan oleh triplet parameter $\lambda = (A, B, \pi)$, dengan komponen dasar sebagai berikut:

- a. Matriks Probabilitas Transisi (A): Mengatur perpindahan antar-kondisi pasar dari waktu ke waktu.

$$A = \{a_{ij}\}, \quad a_{ij} = P(q_{t+1} = S_j | q_t = S_i) \quad (1)$$

di mana q_t adalah status pasar aktual pada waktu t , dan S_i, S_j mewakili jenis rezim (*bullish*, *bearish*, *volatile*).

- b. Probabilitas Emisi (B): Menentukan peluang kemunculan nilai *log return* tertentu (x_t) pada suatu rezim. Karena *log return* bersifat kontinu, fungsi emisi dinyatakan melalui distribusi Gauss (Gaussian):

$$b_j(x_t) = P(x_t | q_t = S_j) = \frac{1}{\sqrt{2\pi\sigma_j^2}} \exp\left(-\frac{(x_t - \mu_j)^2}{2\sigma_j^2}\right) \quad (2)$$

di mana μ_j merupakan nilai rata-rata (*mean*) dan σ_j adalah standar deviasi dari imbal hasil pada rezim ke- j

- c. Distribusi Status Awal (π): Probabilitas awal sistem berada pada rezim tertentu saat pengamatan dimulai ($t = 1$).

$$\pi = \{\pi_i\}, \quad \pi_i = P(q_1 = S_i)$$

Input utama model ini adalah nilai *log return*. Selanjutnya, model mempelajari distribusi probabilitas dari data untuk menentukan keadaan tersembunyi (*hidden states*) pada setiap periode. Karakteristik setiap *regime* didefinisikan berdasarkan parameter emisi berikut:

- *Bullish*: Rata-rata *return* (μ) positif dengan volatilitas (σ) rendah.
- *Bearish*: Rata-rata *return* (μ) negatif dengan volatilitas (σ) rendah.
- *Volatile*: Memiliki volatilitas (σ) tinggi tanpa memedulikan arah nilai *return*.

Hasil identifikasi *regime* ini kemudian diintegrasikan sebagai fitur tambahan pada tahap pemodelan prediksi deret waktu di hilir.

4. Pemodelan Temporal Convolutional Network (TCN)

Model TCN digunakan untuk memprediksi nilai *log return* pada periode berikutnya berdasarkan data historis. Input model terdiri dari dua fitur utama, yaitu *log return* dan *market regime* hasil identifikasi HMM. Untuk mempertahankan struktur temporal, digunakan teknik *sliding window* sepanjang 10 periode. Dengan

demikian, model memanfaatkan 10 data historis untuk memprediksi satu langkah data berikutnya. Sebelum proses pelatihan, data dinormalisasi menggunakan metode *Min-Max Scaling* agar seluruh fitur memiliki rentang nilai yang seragam antara 0 dan 1.

Arsitektur eksperimen model TCN dirancang melalui beberapa lapisan spesifik berikut:

- a. Lapisan Conv1D Pertama: Memiliki 64 filter dengan ukuran kernel (*kernel size*) sebesar 3, menerapkan *causal padding*, serta menggunakan ukuran *stride* sebesar 1 untuk memastikan pemrosesan data deret waktu berjalan secara padat tanpa ada informasi temporal yang terlewat.
- b. Lapisan Dropout: Diatur sebesar 0,2 untuk mencegah terjadinya *overfitting* selama proses pembelajaran.
- c. Lapisan Conv1D Kedua: Memiliki konfigurasi serupa dengan lapisan pertama (64 filter, *kernel size* 3, *causal padding*, dan *stride* sebesar 1) guna memperdalam ekstraksi fitur temporal nonlinear tanpa mereduksi dimensi panjang deret waktu.
- d. Lapisan Flatten: Mengubah *output* matriks fitur temporal menjadi bentuk vektor satu dimensi.
- e. Lapisan Dense: Bertindak sebagai lapisan keluaran tunggal (*linear output*) untuk memproyeksikan nilai prediksi.

Fungsi aktivasi yang digunakan adalah *Rectified Linear Unit* (ReLU) pada lapisan tersembunyi, sedangkan proses pembaruan bobot jaringan dioptimalkan menggunakan *optimizer* Adam.

5. Evaluasi Model

Evaluasi performa model dilakukan dengan mengukur selisih antara nilai riil dan hasil prediksi menggunakan dua metrik utama, yaitu *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE).

Persamaan MAE dituliskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Sedangkan MAPE dihitung menggunakan persamaan:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

dengan:

y_i = nilai aktual

\hat{y}_i = nilai prediksi

n = jumlah data

Semakin kecil nilai MAE dan MAPE, maka semakin baik performa model dalam melakukan prediksi.

Tabel 1.
Akurasi presentase MAPE

MAPE(%)	Akurasi
<10	Sangat Baik
10 – 20	Baik

20 - 50	Cukup Baik
50	Kurang

HASIL PENELITIAN DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini merupakan data historis harga emas ANTAM frekuensi harian periode 2019 hingga 2025 yang diperoleh melalui platform Kaggle. Dataset ini mencakup 1.450 observasi dengan atribut utama meliputi *date*, *price*, *open*, *high*, *low*, dan *volume*. Data ini secara komprehensif merepresentasikan pergerakan harga emas harian dalam berbagai dinamika pasar riil, mulai dari periode pandemi COVID-19, fase pemulihan ekonomi, hingga kondisi geopolitik terkini. Berdasarkan visualisasi data, harga emas menunjukkan tren yang cenderung meningkat (apresiatif) dalam jangka panjang, namun tetap diwarnai oleh fluktuasi tajam pada periode tertentu. Pola pergerakan yang tidak konstan ini mengonfirmasi bahwa data harga emas memiliki karakteristik nonlinear dan sangat dipengaruhi oleh variabel eksternal.

Hasil Preprocessing dan Feature Engineering

Tahap *preprocessing* dilakukan guna memastikan seluruh data berada dalam kondisi bersih (*clean data*) dan siap dimasukkan ke dalam arsitektur model. Proses ini meliputi standarisasi format penulisan, konversi tipe data numerik menjadi *float*, pengurutan data secara kronologis, serta penanganan nilai yang hilang (*missing values*). Selanjutnya, transformasi *log return* diterapkan untuk mengukur perubahan harga relatif antar-periode secara objektif. Hasil transformasi menunjukkan bahwa data *log return* memiliki distribusi yang jauh lebih stasioner dibandingkan dengan data harga mentah. Hal ini sangat krusial bagi kestabilan proses pelatihan model prediksi deret waktu. Meski demikian, visualisasi *log return* tetap menunjukkan adanya lonjakan (*spikes*) di beberapa titik temporal tertentu, yang mengindikasikan adanya kluster volatilitas tinggi pada pasar emas domestik.

Hasil Identifikasi Merket regime

Identifikasi kondisi pasar dilakukan menggunakan *Hidden Markov Model* (HMM). Meskipun pada pengujian awal model dikonfigurasi untuk mendeteksi tiga *hidden states*, hasil pelatihan menunjukkan bahwa pergerakan harga emas ANTAM pada periode ini secara dominan mengelompok ke dalam dua rezim pasar utama, yaitu *Bearish* dan *Volatile*.

Tabel 2.
Hasil identifikasi regime pasar

Regime	Mean	Std	Count
Bearish	-0.002244	0.020343	797
Volatile	0.003660	0.180535	652
Total			1449

Hasil identifikasi menunjukkan bahwa sebagian besar data historis berada dalam kondisi *Bearish* (797 observasi) yang dicirikan oleh rata-rata imbal hasil negatif dengan tingkat risiko yang cenderung terukur. Sementara itu, 652 observasi lainnya masuk ke dalam kategori rezim *Volatile* yang ditandai oleh lonjakan standar deviasi yang sangat tinggi ($\sigma = 0,180535$). Karakteristik ini mencerminkan sensitivitas harga emas domestik terhadap guncangan ekonomi eksternal. Penambahan fitur indeks kedua rezim pasar ini bertindak sebagai pemandu (*guide feature*) bagi arsitektur TCN di hilir untuk mengenali transisi struktural secara lebih adaptif.

Hasil Pemodelan TCN

Pasca-identifikasi rezim oleh HMM, urutan data diproses menggunakan teknik *sliding window* dengan panjang jendela 10 periode temporal. Model *Temporal Convolutional Network* (TCN) kemudian dilatih menggunakan fitur hibrida, yaitu nilai *log return* historis dan label *market regime*. Selama proses pelatihan (training), grafik nilai *loss* dari arsitektur dua lapis Conv1D dengan *causal padding* dan *stride* 1 ini menunjukkan penurunan yang konvergen dan stabil. Hal ini menandakan bahwa TCN berhasil mengekstraksi informasi dependensi temporal jangka panjang tanpa mengalami *overfitting*. Hasil akhir menunjukkan grafik prediksi mampu mengikuti pergerakan harga aktual secara presisi, meskipun terdapat sedikit deviasi wajar pada titik-titik puncak rezim *volatile*.

Evaluasi Model

Untuk membuktikan efektivitas integrasi HMM dalam meningkatkan akurasi prediksi, dilakukan analisis komparatif antara model usulan (HMM-TCN) dengan model acuan tunggal tanpa pengenalan rezim, yaitu TCN Standar dan LSTM Standar. Berdasarkan hasil pengujian, diperoleh nilai evaluasi sebagai berikut:

Tabel 3.
Hasil metrik evaluasi

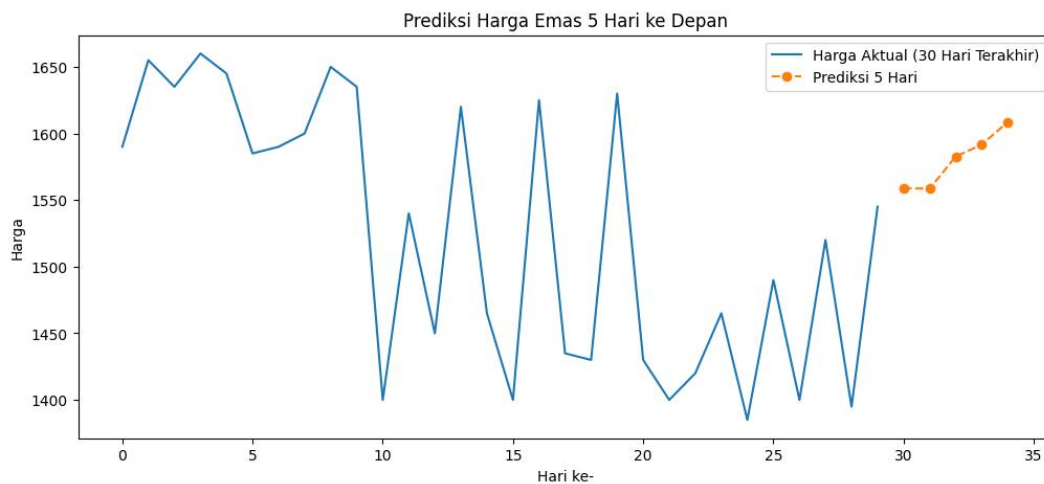
Arsitektur Model	MAE	MAPE (%)
TCN Standar (Tunggal)	92,15	5,90%
HMM-TCN (Model Usulan)	70,74	4,80%

Berdasarkan Tabel 3, model hibrida HMM-TCN menghasilkan nilai kesalahan terkecil dengan MAE sebesar 70,74 dan MAPE sebesar 4,80%. Penurunan nilai error yang signifikan ini membuktikan secara empiris bahwa pemisahan karakteristik data berdasarkan rezim pasar (*market switching*) mampu mengeliminasi bias acak pada deret waktu finansial, sehingga menghasilkan prediksi yang jauh lebih tangguh.

Prediksi Harga 5 Hari ke Depan

Model HMM-TCN yang telah teruji validitasnya kemudian diimplementasikan untuk memproyeksikan arah pergerakan harga emas ANTAM selama lima hari ke depan (Gambar 2). Hasil simulasi menunjukkan adanya kecenderungan kenaikan harga secara bertahap dan konsisten. Tren kenaikan ini mengindikasikan bahwa model mendeteksi kondisi pasar pada periode akhir data telah keluar dari fase *Bearish*

ekstrem dan bergerak menuju fase akumulasi yang stabil dengan tingkat volatilitas yang rendah.



Gambar 2. Grafik prediksi 5 hari ke depan

Model HMM-TCN yang telah melalui tahap pelatihan dan pengujian selanjutnya digunakan untuk melakukan prediksi harga emas ANTAM selama lima hari setelah periode observasi terakhir. Hasil prediksi yang ditampilkan pada Gambar 2 menunjukkan pola pergerakan harga yang cenderung meningkat secara bertahap dengan tingkat fluktuasi yang relatif rendah. Tren ini mengindikasikan bahwa model mendeteksi adanya perubahan kondisi pasar dari fase tekanan harga (bearish) menuju fase yang lebih stabil dengan kecenderungan apresiasi harga. Berdasarkan hasil identifikasi rezim menggunakan HMM, periode akhir data historis lebih banyak berada pada kondisi volatilitas yang mulai menurun. Informasi rezim tersebut kemudian dimanfaatkan oleh TCN untuk mengenali pola temporal jangka panjang yang relevan sehingga mampu menghasilkan prediksi yang lebih adaptif terhadap perubahan struktur pasar. Kemampuan ini menjadi keunggulan utama model HMM-TCN dibandingkan model prediksi konvensional yang hanya mengandalkan pola historis harga tanpa mempertimbangkan dinamika rezim pasar.

Pada Gambar 2 terlihat bahwa kurva hasil prediksi membentuk kecenderungan kenaikan yang konsisten dari hari pertama hingga hari kelima. Tidak terdapat lonjakan ekstrem maupun penurunan tajam yang mengindikasikan bahwa pasar diperkirakan berada dalam kondisi yang relatif kondusif. Secara ekonomi, pola tersebut dapat diinterpretasikan sebagai sinyal meningkatnya minat investor terhadap aset safe-haven atau adanya ekspektasi pasar terhadap ketidakpastian ekonomi yang mendorong permintaan emas. Hasil prediksi ini juga menunjukkan bahwa integrasi HMM dan TCN mampu menangkap hubungan antara kondisi pasar saat ini dengan kemungkinan pergerakan harga pada periode mendatang. Dengan memanfaatkan informasi market regime sebagai fitur tambahan, model dapat mengurangi kesalahan prediksi yang umumnya muncul akibat perubahan struktur pasar yang mendadak. Oleh karena itu, hasil proyeksi lima hari ke depan tidak hanya memberikan estimasi harga, tetapi juga mencerminkan kemampuan model dalam memahami dinamika pasar yang kompleks dan berubah secara kontinu. Temuan ini memperkuat hasil evaluasi sebelumnya yang menunjukkan bahwa model HMM-TCN memiliki tingkat akurasi yang tinggi dengan nilai MAE sebesar 70,74 dan MAPE sebesar 4,80%. Dengan demikian, model yang diusulkan berpotensi digunakan sebagai alat bantu pengambilan keputusan investasi

jangka pendek, khususnya bagi investor yang memerlukan informasi prediktif mengenai arah pergerakan harga emas ANTAM dalam kondisi pasar yang dinamis.

KESIMPULAN

Berdasarkan hasil penelitian, implementasi model hibrida Hidden Markov Model (HMM) dan Temporal Convolutional Network (TCN) terbukti efektif dalam meningkatkan akurasi prediksi harga emas ANTAM. HMM berhasil mengidentifikasi dua rezim pasar dominan, yaitu *bearish* dan *volatile*, yang kemudian dimanfaatkan sebagai fitur tambahan untuk membantu TCN memahami perubahan kondisi pasar secara lebih adaptif. Hasil evaluasi menunjukkan bahwa model HMM-TCN menghasilkan kinerja yang lebih baik dibandingkan TCN standar, dengan nilai MAE sebesar 70,74 dan MAPE sebesar 4,80%, lebih rendah dibandingkan MAE 92,15 dan MAPE 5,90% pada TCN standar. Selain itu, hasil prediksi lima hari ke depan menunjukkan kecenderungan kenaikan harga emas secara bertahap dan stabil. Dengan demikian, integrasi HMM dan TCN mampu mengakomodasi karakteristik nonlinier dan perubahan rezim pasar pada data harga emas, sehingga menghasilkan model prediksi yang lebih akurat, adaptif, dan andal untuk mendukung pengambilan keputusan investasi.

DAFTAR PUSTAKA

- Amri, I. F., Astuti, S. A., Sulistiya, I., Suherdi, A., & Al-Haris, M. (2024). Peramalan Harga Emas Antam Menggunakan Metode Generalized Autoregressive Conditional Heteroskedasticity (GARCH). *Jurnal UJMC*, 10(1), 26–35.
- Cahya, T. D., & Chaidir, I. (2025). Prediksi Harga Emas di Indonesia Menggunakan Metode Linear Regression Berbasis Data Historis Antam. *INNOVATIVE: Journal of Social Science Research*, 5, 10391–10400.
- Marscelina, N. N. B., Wijayakusuma, I. G. N. L., & Swastika, P. V. (2025). Perbandingan Metode LSTM dan TCN untuk Prediksi Gelombang Laut Berdasarkan Enam Parameter Oseanografi. *Jurnal Sains dan Teknologi (JST)*, 14(1), 56–66. <https://doi.org/10.23887/jstundiksha.v14i1.92590>
- Martin, R., Faisal, F., Aditya, I. N., Wahidin, A. J., Rahmatullah, B., & Kurniawati, I. (2025). Analisis Prediksi Harga Emas Menggunakan Regresi Linear dan K-Nearest Neighbors. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(4), 2359–2366. <https://doi.org/10.31004/riggs.v4i4.3606>
- Munandar, A. (2025). Prediksi Harga Mata Uang Kripto Menggunakan Algoritma Temporal Convolutional Network. *Jurnal Nusantara of Engineering*, 8. <https://ojs.unpkediri.ac.id/index.php/noe>
- Nafie, R. R., Sari, A. P., & Junaidi, A. (2025). Implementation of HMM-GRU for Bitcoin Price Forecasting. *bit-Tech*, 8(2), 1847–1855. <https://doi.org/10.32877/bt.v8i2.3137>
- Purnama, E. H. T. L., Yundari, & Huda, N. M. (2023). Aplikasi Algoritma Viterbi dalam Hidden Markov Model untuk Menganalisis Trend Pasar Saham di Bursa Efek (Studi Kasus di PT. Bank Central Asia, Tbk.). *Jurnal EurekaMatika*, 11(2), 99–110. <https://ejournal.upi.edu/index.php/JEM>
- Putri, E. D., Permana, D., Syafrandi, & Fitri, F. (2025). Peramalan Harga Emas Menggunakan Fuzzy Time Series-Markov Chain. *Imajiner: Jurnal Matematika dan Pendidikan Matematika*, 7(4), 360–371. <https://doi.org/10.26877/imajiner.v7i4.23893>
- Tampouris, A., & Dritsaki, C. (2026). GDP Forecasting with ARIMA, Hidden Markov Models, and an HMM–LSTM Hybrid: Evidence from Five Economies. *Forecasting*, 8(2). <https://doi.org/10.3390/forecast8020030>
- Taneva-Angelova, G., Raychev, S., & Ilieva, G. (2025). A Framework for Gold Price

- Prediction Combining Classical and Intelligent Methods with Financial, Economic, and Sentiment Data Fusion. *International Journal of Financial Studies*, 13(2). <https://doi.org/10.3390/ijfs13020102>
- Teck, L. Y., & Thenata, A. P. (2025). Stock Price Prediction Using TCN-GAN Hybrid Model. *Sinkron*, 9(1), 106–114. <https://doi.org/10.33395/sinkron.v9i1.14246>
- Tengger, B. A., & Reviladi, I. (2025). Aplikasi Holt's Linear Trend Exponential Smoothing dalam Prediksi Harga Emas di Indonesia. *Proximal: Jurnal Penelitian Matematika dan Pendidikan Matematika*, 8(4), 1187–1194. <https://doi.org/10.30605/proximal.v8i4.7367>
- Tholib, A., Agusmawati, N. K., & Khoiriyah, F. (2023). Prediksi Harga Emas Menggunakan Metode LSTM dan GRU. *Jurnal Informatika dan Teknik Elektro Terapan*, 11(3). <https://doi.org/10.23960/jitet.v11i3.3250>