

Pembelajaran Multi-Task Berbasis Citra Candlestick untuk Klasifikasi Pola dan Prediksi Arah Cryptocurrency

¹Hasriadi, ²Iqbal

^{1,2} Program Studi Teknik Informatika, Universitas Lamappapoleonro, Soppeng, Indonesia

¹hasriadi@unipol.ac.id ²Iqbal@unipol.ac.id

*Penulis Korespondensi

Diajukan : 10/06/2026

Diterima : 24/06/2026

Dipublikasi : 28/06/2026

ABSTRAK

Pasar cryptocurrency memiliki volatilitas yang sangat tinggi sehingga analisis teknikal manual terhadap pola candlestick menjadi sulit dilakukan secara konsisten. Pendekatan deep learning berbasis citra berpotensi mengotomatisasi identifikasi pola sekaligus meningkatkan kemampuan prediksi arah harga. Penelitian ini bertujuan mengembangkan model pembelajaran multi-task berbasis citra candlestick yang mampu secara simultan mengklasifikasikan sepuluh pola candlestick dan memprediksi arah pergerakan harga cryptocurrency tiga hari ke depan. Data historis OHLC harian dari lima aset cryptocurrency (BTC, ETH, XRP, DOGE, dan SOL) periode Januari 2018 hingga Desember 2025 dikumpulkan dan dibagi secara kronologis menjadi data latih (70%), validasi (15%), dan uji (15%). Setiap jendela yang terdiri atas 10 candle dirender menjadi citra berukuran 128×128 piksel dan diproses menggunakan backbone EfficientNetB0 yang telah dipra-latih. Tiga skema eksperimen, yaitu E1 (klasifikasi pola), E2 (prediksi arah), dan E3 (multi-task), dievaluasi menggunakan tiga seed acak, uji McNemar, dan interval kepercayaan Bootstrap 95%. Hasil penelitian menunjukkan bahwa model multi-task (E3) mencapai akurasi klasifikasi pola sebesar $81.58\% \pm 0.39\%$ dan ROC-AUC prediksi arah sebesar 0.7649 ± 0.0046 . Dibandingkan model single-task (E2), E3 meningkatkan skor F1 sebesar +0.2021 (95% CI: [0.161; 0.241]) dan ROC-AUC sebesar +0.0402 (95% CI: [0.016; 0.063]), meskipun perbedaan akurasi biner tidak signifikan secara statistik (McNemar $p = 0.827$). Temuan ini menunjukkan bahwa pembelajaran multi-task menghasilkan representasi fitur yang lebih informatif, probabilitas prediksi yang lebih terkalibrasi, serta kinerja yang lebih stabil dibandingkan pendekatan single-task. Dengan demikian, klasifikasi pola candlestick dapat berfungsi sebagai tugas auxiliary yang meningkatkan kualitas representasi fitur dan kemampuan prediksi arah harga cryptocurrency.

Kata Kunci: analisis teknikal; deep learning; EfficientNetB0; pengenalan pola; peramalan harga

I. PENDAHULUAN

Pasar cryptocurrency telah berkembang menjadi salah satu kelas aset paling dinamis di dunia, dengan kapitalisasi pasar gabungan yang melampaui tiga triliun dolar AS pada akhir 2024 (Aritonang, 2024). Karakteristik utama pasar ini adalah volatilitas harga yang sangat tinggi, aktivitas perdagangan yang berlangsung 24 jam tanpa henti, serta sensitivitas terhadap sentimen global dan kebijakan regulasi. Kondisi ini menciptakan tantangan serius bagi investor maupun peneliti dalam membangun model prediktif yang andal.

Analisis teknikal berbasis pola candlestick merupakan pendekatan yang telah digunakan secara luas oleh para trader dalam mengidentifikasi peluang perdagangan (Ardimansyah et al., 2025). Pola seperti doji, hammer, engulfing, dan morning star secara historis dianggap mengandung informasi tentang sentimen pasar dan kemungkinan pembalikan tren (Uzun et al., 2024). Namun, identifikasi pola secara manual bersifat subjektif, memerlukan keahlian tinggi, dan tidak skalabel

untuk pemantauan banyak aset secara bersamaan. Otomasi deteksi pola candlestick melalui pendekatan berbasis data menjadi kebutuhan yang mendesak.

Sebagian besar penelitian terdahulu mengenai prediksi harga cryptocurrency berfokus pada model sekuensial berbasis data numerik, seperti LSTM dan GRU (Muslim & Hamzah, 2025; Rizkilloh & Widiyanesti, 2022; Manek et al., 2025). Meskipun pendekatan ini efektif untuk menangkap dependensi temporal, representasi numerik OHLC mentah kurang mampu mengkodekan informasi visual-struktural yang terkandung dalam pola candlestick, yaitu informasi yang secara natural ditangkap oleh mata manusia dalam bentuk citra. Penelitian Zhang et al. (2023) pada pasar ETF menunjukkan bahwa representasi berbasis citra dapat meningkatkan interpretabilitas dan akurasi prediksi tren dibandingkan pendekatan berbasis fitur numerik.

Kesenjangan penelitian yang teridentifikasi adalah belum adanya studi yang mengintegrasikan klasifikasi pola candlestick secara eksplisit dan prediksi arah harga dalam satu kerangka pembelajaran multi-task berbasis citra pada data cryptocurrency multi-aset. Penelitian Jearanaitanakij dan Passaya (2019) memanfaatkan citra candlestick untuk memprediksi tren saham menggunakan pendekatan single-task, namun terbatas pada satu aset dan tidak memanfaatkan informasi pola candlestick sebagai sumber supervisi tambahan. Mersal et al. (2025) memperluas penggunaan citra candlestick untuk prediksi tren pasar, tetapi masih memfokuskan model pada satu tugas prediksi tanpa mengintegrasikan proses klasifikasi pola secara eksplisit. Akibatnya, potensi hubungan antara pengenalan pola candlestick dan prediksi arah harga belum dieksplorasi secara optimal.

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan pendekatan pembelajaran multi-task berbasis citra candlestick yang secara simultan melakukan klasifikasi sepuluh pola candlestick dan prediksi arah pergerakan harga cryptocurrency tiga hari ke depan. Penelitian ini berangkat dari hipotesis bahwa pembelajaran multi-task mampu menghasilkan representasi fitur yang lebih informatif melalui pemanfaatan informasi pola candlestick sebagai tugas auxiliary yang mendukung prediksi arah harga. Kontribusi utama penelitian ini meliputi: (1) pengembangan kerangka pembelajaran multi-task berbasis citra untuk analisis candlestick pada pasar cryptocurrency, (2) evaluasi komprehensif pada lima aset cryptocurrency menggunakan beberapa seed acak dan pengujian signifikansi statistik, serta (3) penyediaan bukti empiris mengenai pengaruh pembelajaran multi-task terhadap peningkatan kualitas representasi fitur, stabilitas pelatihan, dan kalibrasi probabilitas prediksi arah harga.

II. STUDI LITERATUR

Penelitian prediksi harga cryptocurrency menggunakan pendekatan *deep learning* telah berkembang pesat dalam beberapa tahun terakhir. Muslim & Hamzah (2025) membandingkan LSTM dan GRU untuk peramalan harga Bitcoin dan menemukan bahwa GRU menghasilkan RMSE lebih rendah pada kondisi data yang berfluktuasi. Dapubeang & Malahina (2025) juga membandingkan kedua arsitektur untuk prediksi XRP dan menyimpulkan bahwa LSTM mengungguli GRU pada data dengan pola musiman yang kuat. Rizkilloh & Widiyanesti (2022) menggunakan LSTM untuk prediksi harga multivariat cryptocurrency dengan *mean absolute percentage error* (MAPE) di bawah 5% pada kondisi pasar yang relatif stabil. Ketiga penelitian ini mengkonfirmasi keunggulan model sekuensial untuk data deret waktu, namun tidak mempertimbangkan representasi visual yang mengandung informasi struktural pola candlestick.

Pendekatan berbasis citra untuk analisis pasar keuangan mulai mendapat perhatian. Zhang et al. (2023) mengembangkan model *deep learning* berbasis citra yang dapat diinterpretasi untuk prediksi tren pada pasar ETF, menunjukkan bahwa representasi visual lebih informatif dibandingkan representasi numerik untuk deteksi pola pergerakan harga jangka pendek. Ng & Ling (2023) mengevaluasi model LSTM dan CNN untuk prediksi harga cryptocurrency dan menemukan bahwa CNN lebih unggul dalam menangkap fitur lokal dalam pola harga. Uzun et al. (2024) menggunakan metode *rule-based* untuk mengenali pola candlestick pada data deret waktu cryptocurrency dan menetapkan bahwa pola tertentu seperti doji dan engulfing memiliki frekuensi

kemunculan yang signifikan pada data kripto harian.

Studi terkait CNN dan pola candlestick dilakukan oleh Jearanaitanakij & Passaya (2019) yang menggunakan CNN untuk memprediksi tren saham jangka pendek berdasarkan gambar pola candlestick. Mersal et al. (2025) memperluas pendekatan ini dengan mengaplikasikan CNN berbasis pola candlestick Jepang untuk prediksi tren pasar dan memperoleh akurasi yang kompetitif. Namun, kedua studi tersebut menggunakan pendekatan *single-task* tanpa memanfaatkan informasi label pola candlestick secara eksplisit sebagai sinyal supervisi tambahan. Hasriadi et al. (2026) mengeksplorasi pendekatan Gramian Angular Field (GAF) dikombinasikan dengan *deep learning* hibrid untuk analisis pola candlestick cryptocurrency, yang menunjukkan bahwa transformasi citra dari data OHLC dapat menghasilkan representasi yang kaya untuk pembelajaran.

Identifikasi *gap* penelitian menunjukkan bahwa belum ada studi yang: (1) menggunakan representasi citra candlestick langsung (bukan GAF atau fitur numerik terderivasi) sebagai input CNN, (2) mengintegrasikan klasifikasi pola candlestick eksplisit dan prediksi arah harga dalam kerangka *multi-task learning*, dan (3) mengevaluasi efek regularisasi dari pembelajaran multi-task secara statistik pada data cryptocurrency multi-aset. Penelitian ini dirancang untuk mengisi kesenjangan tersebut.

III. METODE

a. Pengumpulan Data

Data historis OHLC (*Open, High, Low, Close*) harian untuk lima aset cryptocurrency antara lain BTC-USD, ETH-USD, XRP-USD, DOGE-USD, dan SOL-USD, dikumpulkan menggunakan pustaka *yfinance* untuk periode 1 Januari 2018 hingga 31 Desember 2025. Total data mentah yang diperoleh adalah 2.921 hari perdagangan untuk BTC-USD. Data dibagi secara kronologis (tanpa pengacakan) menjadi tiga subset: latih 70% (hingga Agustus 2023), validasi 15% (Agustus 2023–Oktober 2024), dan pengujian 15% (Oktober 2024–Desember 2025), menghasilkan 2.011 jendela uji dari kelima aset.

b. Prapemrosesan dan Pembentukan Jendela

Setiap aset diproses secara independen untuk mencegah kebocoran informasi lintas aset. *Missing value* diatasi dengan *forward fill* maksimum tiga candle berturutan, sedangkan *outlier* diclip menggunakan batas $IQR \times 3$ yang dihitung hanya dari data latih. Normalisasi *min-max* per aset diterapkan dengan *scaler* yang di-fit eksklusif pada data latih. Pembentukan jendela menggunakan parameter *window_size* = 10 candle dan *prediction horizon* tiga hari, artinya label arah ditentukan berdasarkan perbandingan harga *close* pada candle ke-(t+3) terhadap candle ke-t: bernilai 1 (naik) jika lebih tinggi, dan 0 (turun/flat) jika lebih rendah atau sama.

c. Rendering Citra Candlestick


Setiap jendela 10 candle dirender menjadi citra candlestick berukuran 128×128 piksel dengan 3 saluran warna (RGB) menggunakan *library matplotlib*. Candle bullish ditampilkan dalam warna hijau (#00C800) dan candle bearish dalam warna merah (#C80000) pada latar putih. Augmentasi data ringan (*Gaussian noise*, *brightness jitter*, *contrast jitter*, dan *random erasing* dengan probabilitas 0.2) diterapkan hanya pada data latih untuk mengurangi *overfitting*. *Flip* horizontal dan vertikal dinonaktifkan karena akan merusak informasi temporal dan harga pada citra candlestick.

d. Pelabelan Pola Candlestick

Sepuluh kelas pola candlestick dilabeli menggunakan detektor berbasis aturan deterministik: (0) *no_pattern*, (1) *doji*, (2) *hammer*, (3) *shooting_star*, (4) *bullish_engulfing*, (5) *bearish_engulfing*, (6) *bullish_harami*, (7) *bearish_harami*, (8) *morning_star*, dan (9) *evening_star*. Label diambil dari candle terakhir dalam jendela (*endpoint window*) sehingga tidak

terjadi kebocoran masa depan. Pola *three_white_soldiers* dan *three_black_crows* awalnya dipertimbangkan, namun dikeluarkan karena jumlah sampel pengujian kurang dari 10, yang tidak memadai untuk estimasi F1 yang andal secara statistik.

e. Arsitektur Model



Gambar 1. Arsitektur Model

Model Multi-Task CNN dibangun di atas *backbone* EfficientNetB0 *pretrained* ImageNet dengan pembekuan parameter hingga lapisan *features* 2. Fitur visual dari *backbone* (dimensi 512) digabungkan dengan keluaran *NumericalEncoder* (MLP kecil yang mengkodekan 10 nilai *log-return* per jendela, dimensi output 64), menghasilkan vektor fitur gabungan berdimensi 576. Vektor ini kemudian diteruskan ke dua *head* independen: (1) *pattern head* (linear 576→256→10 dengan dropout 0.3) untuk klasifikasi pola, dan (2) *direction head* (linear 576→128→1 dengan dropout 0.3) untuk prediksi arah biner. Fungsi loss untuk klasifikasi pola menggunakan *Focal Loss* ($\gamma = 2.5$) untuk menangani ketidakseimbangan kelas, sedangkan prediksi arah menggunakan *BCEWithLogitsLoss* dengan *pos_weight* otomatis dari rasio kelas di data latih. Total kerugian dihitung sebagai: $L_{total} = \lambda_p \times L_{pattern} + \lambda_d \times L_{direction}$, dengan $\lambda_p = 1.0$ dan $\lambda_d = 0.3$ pada eksperimen E3.

f. Skema Eksperimen

Tiga skema eksperimen dirancang untuk mengisolasi kontribusi masing-masing komponen: E1 ($\lambda_p=1$, $\lambda_d=0$, hanya klasifikasi pola), E2 ($\lambda_p=0$, $\lambda_d=1$, hanya prediksi arah), dan E3 ($\lambda_p=1$, $\lambda_d=0.3$, multi-task). Setiap eksperimen dijalankan dengan tiga *random seed* (42, 123, 456) untuk mengukur stabilitas hasil. Pelatihan menggunakan optimizer AdamW ($lr = 3 \times 10^{-4}$, weight decay = 5×10^{-4}), penjadwalan *CosineAnnealingWarmRestarts* ($T_0=20$), dan *early stopping* dengan *patience* 30 pada metrik *val_combined_f1*.

g. Evaluasi

Untuk tugas klasifikasi pola, metrik yang digunakan adalah *accuracy* dan *F1-macro*. Untuk tugas prediksi arah, metrik yang digunakan adalah *accuracy*, F1, ROC-AUC, dan PR-AUC. *Threshold* optimal ditentukan per model menggunakan metode Youden's J pada data validasi. Perbandingan E3 vs. E2 menggunakan uji McNemar (untuk prediksi biner per sampel) dan *Bootstrap* Δ -CI 95% (1.000 iterasi) untuk selisih ROC-AUC, F1, dan PR-AUC.

IV. HASIL DAN PEMBAHASAN


Kurva Pelatihan

Gambar 2 menyajikan kurva loss pelatihan dan validasi untuk ketiga eksperimen.



Gambar 2. Kurva loss pelatihan dan validasi

Model E1 menunjukkan konvergensi stabil dengan *val_loss* yang mengikuti *train_loss* secara konsisten. Sebaliknya, E2 menunjukkan gejala *overfitting* parah, di mana *train_loss* turun hingga 0.27 sementara *val_loss* meningkat hingga 1.68 setelah epoch ke-10. Model E2 berhenti lebih awal pada epoch 1–7 (tergantung seed), mengindikasikan bahwa tanpa supervisi dari tugas pola, *backbone* tidak cukup terstabilkan oleh data arah yang sangat noisy. Model E3 menunjukkan pelatihan yang paling stabil, dengan *best checkpoint* ditemukan pada epoch 26–33, memperkuat argumen bahwa tugas pola bertindak sebagai regularisasi implisit.

Validation Combined F1 per Epoch (mean $\pm$ range, 3 seeds)

Gambar 3. Kurva F1 validasi

Gambar 3 memperlihatkan kurva F1 validasi gabungan dari tiga seed beserta *band* min-maks. E3 memiliki lebar *band* paling sempit, mengkonfirmasi stabilitas pelatihan yang lebih tinggi dibanding E1 dan E2.


Kinerja Klasifikasi Pola Candlestick

Tabel 1 merangkum perbandingan kinerja keseluruhan.

TABEL 1: Perbandingan kinerja E1, E2, E3 dan baseline


Model	Pattern Accuracy (%)	Pattern F1-macro	Direction Accuracy (%)	Direction F1	ROC-AUC	PR-AUC
Majority Class	45.90	0.063	66.43	0.000	0.500	0.336
Random	10.34	0.057	50.87	0.409	0.512	0.345
E1 (Pattern Only)	81.07 $\pm$ 0.77	0.556 $\pm$ 0.026	—	—	—	—
E2 (Direction Only)	—	—	68.09 $\pm$ 0.66	0.418 $\pm$ 0.058	0.756 $\pm$ 0.024	0.524 $\pm$ 0.025
E3 (Multi-Task)	81.58 $\pm$ 0.39	0.564 $\pm$ 0.016	67.99 $\pm$ 0.30	0.538 $\pm$ 0.141	0.765 $\pm$ 0.005	0.541 $\pm$ 0.007

Pada tugas klasifikasi pola, model E3 mencapai akurasi rata-rata 81.58% $\pm$ 0.39% dan F1-macro 0.5639 $\pm$ 0.0164, mengungguli E1 (akurasi 81.07% $\pm$ 0.77%, F1-macro 0.5557 $\pm$ 0.0258) meskipun E1 dirancang khusus untuk tugas ini. Perbedaan ini, meskipun kecil, menunjukkan bahwa sinyal dari prediksi arah memberikan informasi tambahan yang berguna bagi *backbone* untuk merepresentasikan citra candlestick secara lebih diskriminatif. Kedua model CNN jauh melampaui *baseline* mayoritas kelas (akurasi 45.90%, F1-macro 6.29%) maupun *baseline* acak (akurasi 10.34%, F1-macro 5.69%).



Gambar 4. Confusion matrix Pattern task

Gambar 4 menyajikan *confusion matrix* yang dinormalisasi per baris untuk E3 seed 42. Dua kelas dominan, yaitu *no_pattern* dan *doji*, menunjukkan recall tinggi (masing-masing 75.3% dan 95.5%), mencerminkan proporsi kemunculannya dalam data pengujian (45.9% dan 39.9%).



Gambar 5. Per-class F1 Score

Gambar 5 membandingkan F1 per kelas antara E1 dan E3. Kelas-kelas langka seperti *morning_star* ($n=14$) dan *evening_star* ($n=11$) mencapai F1 masing-masing 0.387 dan 0.471, yang tergolong cukup mengingat keterbatasan jumlah sampel. Kelas *hammer* ($n=28$) dan *doji* ($n=802$) mencapai F1 tertinggi kedua masing-masing 0.655 dan 0.960, menunjukkan model mampu mengenali pola dengan karakteristik visual yang khas secara konsisten.


Kinerja Prediksi Arah Harga

Pada prediksi arah, E3 mencapai ROC-AUC rata-rata 0.7649 ± 0.0046 , melampaui E2 (0.7555 ± 0.0236) dan jauh di atas ketiga *baseline* (ROC-AUC 0,500–0,512). Hasil ini konsisten dengan temuan Ng & Ling (2023) yang melaporkan ROC-AUC CNN berkisar 0.70–0.78 untuk prediksi harga cryptocurrency, dan lebih tinggi dari laporan Hasriadi & Iqbal (2026) yang menggunakan pendekatan hibrid LSTM-GRU berbasis data numerik pada data yang sama.

Perlu dicatat bahwa distribusi kelas arah dalam data pengujian tidak seimbang: 33.6% naik dan 66.4% turun, mencerminkan kondisi pasar *bearish* pada periode Oktober 2024 sampai dengan Desember 2025. Ketidakseimbangan ini menyebabkan *baseline* mayoritas kelas (selalu prediksi "turun") mencapai akurasi 66.43% dengan $F1 = 0.000$, yang secara numerik tampak tinggi tetapi tidak berguna untuk aplikasi perdagangan. Oleh karena itu, ROC-AUC digunakan sebagai metrik utama karena bersifat *threshold-free* dan tidak terpengaruh oleh distribusi kelas.


Analisis Signifikansi Statistik

Gambar 6 memvisualisasikan ringkasan perbandingan metrik E2 vs. E3 dengan *error bar* multi-seed.

Gambar 6. Perbandingan metrik E2 vs. E3 dengan *error bar* multi-seed

Uji McNemar pada prediksi biner E3 vs. E2 menghasilkan $\chi^2 = 0.048$, $p = 0.827$, artinya kedua model membuat kesalahan pada sampel yang hampir identik ketika dievaluasi pada *threshold* optimal masing-masing. Namun, uji *Bootstrap* Δ -CI 95% menunjukkan perbedaan yang signifikan pada metrik berbasis probabilitas: Δ F1 = +0.2021 (95% CI: [0.161; 0.241]), Δ ROC-AUC = +0.0402 (95% CI: [0.016; 0.063]), dan Δ PR-AUC = +0.0519 (95% CI: [0.015; 0.089]).


Temuan ini mengungkap peran kritis pembelajaran multi-task: model E3 tidak mengklasifikasikan lebih banyak sampel secara benar pada level biner, namun menghasilkan probabilitas prediksi yang jauh lebih terkalibrasi. Hal ini dapat dijelaskan oleh fakta bahwa tugas pola memberikan gradien yang informatif dan stabil kepada *backbone* EfficientNetB0 selama pelatihan, mencegah degenerasi representasi yang terjadi pada E2 (E2 berhenti di epoch 1–7 karena sinyal arah harga saja terlalu noisy untuk menstabilkan pelatihan). Efek serupa dilaporkan dalam literatur *multi-task learning* umum, di mana tugas *auxiliary* yang berkorelasi secara semantik bertindak sebagai regularisasi implisit (Armin et al., 2022).



Gambar 7. Stabilitas antar seed

Gambar 7 menyajikan *box plot* stabilitas antar seed untuk E2 dan E3. Terlihat bahwa varians ROC-AUC E3 ($\sigma = 0.005$) secara signifikan lebih rendah dibandingkan E2 ($\sigma = 0.024$), mengkonfirmasi bahwa multi-task learning juga meningkatkan stabilitas pelatihan.

Perbandingan lebih detail per seed ditampilkan pada Gambar 8. Dibawah ini:



Gambar 8. Perbandingan Metrik AUC

Gambar 8. Perbandingan AUC Metrics menunjukkan nilai ROC-AUC dan PR-AUC pada tiga seed berbeda untuk model E2 dan E3. Secara umum, E3 menghasilkan nilai yang lebih konsisten antar-seed serta memiliki rata-rata ROC-AUC dan PR-AUC yang sedikit lebih tinggi dibandingkan E2, menunjukkan bahwa pendekatan multi-task learning memberikan peningkatan kinerja yang stabil pada tugas prediksi arah harga.

Penelitian ini memperluas pendekatan Jearanaitanakij & Passaya (2019) dan Mersal et al. (2025) yang menggunakan CNN berbasis citra candlestick secara *single-task*, dengan menambahkan komponen multi-task dan dataset cryptocurrency multi-aset yang lebih besar. ROC-AUC 0,7649 yang dicapai lebih tinggi dibandingkan laporan Ng & Ling (2023) (CNN: 0.72–0.76) untuk tugas yang serupa. Keunggulan representasi berbasis citra dibandingkan pendekatan numerik juga sejalan dengan temuan Zhang et al. (2023) yang menunjukkan peningkatan prediksi tren pasar melalui transformasi visual data OHLC. Dibandingkan Hasriadi et al. (2026) yang menggunakan GAF sebagai representasi citra, pendekatan citra candlestick langsung dalam penelitian ini memiliki keunggulan interpretabilitas karena menghasilkan representasi yang dapat langsung dibaca oleh praktisi.

Penelitian ini memiliki beberapa keterbatasan. Dataset hanya mencakup lima aset cryptocurrency dan menggunakan data harian sehingga belum merepresentasikan perilaku pasar intraday. Selain itu, pelabelan pola candlestick dilakukan menggunakan aturan deterministik yang mungkin tidak sepenuhnya menangkap variasi interpretasi praktisi. Oleh karena itu, generalisasi hasil ke aset lain dan timeframe berbeda perlu diuji lebih lanjut.

V. KESIMPULAN

Penelitian ini berhasil mengembangkan model pembelajaran multi-task berbasis citra candlestick yang secara simultan mengklasifikasikan sepuluh pola candlestick dan memprediksi arah harga tiga hari ke depan pada lima aset cryptocurrency. Model multi-task (E3) mencapai akurasi klasifikasi pola $81.58\% \pm 0.39\%$ dan ROC-AUC prediksi arah 0.7649 ± 0.005 , melampaui seluruh *baseline* dan model *single-task*. Uji signifikansi statistik membuktikan bahwa pembelajaran multi-task secara signifikan meningkatkan kualitas probabilitas prediksi arah ($\Delta F1 = +0.2021$; $\Delta \text{ROC-AUC} = +0.0402$; keduanya $p < 0.05$ via *Bootstrap CI*), meskipun akurasi biner tidak berbeda signifikan (McNemar $p = 0.827$). Temuan ini mengkonfirmasi hipotesis bahwa tugas klasifikasi pola berfungsi sebagai regularisasi implisit yang menstabilkan pelatihan *backbone* dan meningkatkan kalibrasi probabilitas prediksi arah, suatu manfaat yang sangat relevan untuk aplikasi manajemen risiko perdagangan. Penelitian mendatang disarankan untuk mengeksplorasi eksperimen komparasi representasi citra (candlestick langsung vs. GAF), perluasan ke data *intraday*, serta integrasi informasi lintas aset melalui mekanisme *attention*.

VI. REFERENSI

- Afrinanda, R., dkk. (2023). Hybrid model for sentiment analysis of Bitcoin prices using deep learning. *MATRIK*, 22(2), 309–324.
- Andree, A. F. P., Tri, T. B. K., Misinem, & Deshinta, D. A. D. (2023). Implementasi analisis sentimen dan model deep learning untuk prediksi harga Bitcoin. *Jurnal Jupiter*, 15(1), 403–412.
- Ardimansyah, Ibrahim, A., & Susanto, C. (2025). Analisis pola candlestick engulfing pada pasangan XAUUSD menggunakan expert advisor MetaTrader 5. *SISITI: Seminar Ilmiah Sistem Informasi dan Teknologi Informasi*, 14(2), 41–49.
- Aritonang, D. E. (2024). *Analisis sentimen publik terhadap cryptocurrency di Indonesia* (Disertasi). Universitas Atma Jaya Yogyakarta.
- Armin, A. L., Hendra, H. M., & Supri, S. A. (2022). Implementation of long short-term memory and gated recurrent units on grouped time-series data to predict stock prices accurately. *Journal of Big Data*, 9, Artikel 89.
- Dapubeang, M. S. R. A., & Malahina, E. U. (2025). Prediksi harga XRP menggunakan LSTM dan GRU. *Jurnal Manajemen Informatika & Teknologi*, 5(2), 107–124.
- Hasriadi, & Iqbal. (2026). Prediksi harga Bitcoin multivariat OHLC berbasis hybrid LSTM–GRU dan sentimen berita. *Jurnal Minfo Polgan*, 14(2). doi: <https://doi.org/10.33395/jmp.v14i2.15843>
- Hasriadi, Razak, M., & Jalil, A. (2026). Analisis pola candlestick cryptocurrency menggunakan Gramian Angular Field dan deep learning hibrid. *SISTEMASI*, 15(2). doi: <https://doi.org/10.32520/stmsi.v15i2.5883>
- Iqbal, I., & Hasriadi, H. (2026). Analisis perbandingan keamanan smart contract Ethereum menggunakan Slither dan Mythril. *REMIK: Riset dan E-Jurnal Manajemen Informatika Komputer*, 10(1), 368–375.

- Jearanaitanakij, K., & Passaya, B. (2019). Predicting short trend of stocks by using convolutional neural network and candlestick patterns. Dalam *Proceedings of the 4th International Conference on Information Technology (InCIT)* (hlm. 159–162). Bangkok, Thailand.
- Manek, U. F., Nur'Afiah, S., & Moka, S. (2025). Prediksi harga cryptocurrency Bitcoin dengan pendekatan GRU. *JATI*, 9(5), 7667–7673.
- Mersal, E. R., Karaoğlu, K. M., & Kutucu, H. (2025). Enhancing market trend prediction using convolutional neural networks on Japanese candlestick patterns. *PeerJ Computer Science*, 11, e2719.
- Muhammad, M. L. P., & Hastari, U. (2023). Pendekatan deep learning menggunakan metode LSTM untuk prediksi harga Bitcoin. *IJCSR: The Indonesian Journal of Computer Science Research*, 2(2), 43–50.
- Muslim, I., & Hamzah, M. A. (2025). Perbandingan algoritma LSTM dan GRU untuk peramalan Bitcoin. *SEHATI*, 11(1), 486–494.
- Ng, S. W., & Ling, L. S. (2023). Evaluation of cryptocurrency price prediction using LSTM and CNN models. *International Journal on Informatics Visualization*, 7(3-2), 2016–2024.
- Nurhopipah, A., & Larasati, N. A. (2021). CNN hyperparameter optimization using random grid coarse-to-fine search for face classification. *KINETIK: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, 6(1), 47–56.
- Rizkillah, M. F., & Widiyanesti, S. (2022). Prediksi harga cryptocurrency menggunakan algoritma long short-term memory (LSTM). *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(1), 25–31.
- Timothy, T. B. S., Cahya, I., & Novanto, N. Y. (2023). Penerapan algoritma long short-term memory (LSTM) berbasis multi fungsi aktivasi terbobot dalam prediksi harga Ethereum. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 7(3), 1101–1107.
- Uzun, I., Lobachev, M., Kharchenko, V., Schöler, T., & Lobachev, I. (2024). Candlestick pattern recognition in cryptocurrency price time-series data using rule-based data analysis methods. *Computation*, 12(7), Artikel 132.
- Zhang, R., Zhao, C., & Lin, G. (2023). Interpretable image-based deep learning for price trend prediction in ETF markets. *The European Journal of Finance*, 29(5), 521–549.