

DETEKSI POLA CANDLESTICK MENGGUNAKAN YOLOV8 UNTUK ANALISIS TEKNIKAL BERBASIS CITRA

PENULIS

¹⁾Maulana Manshur, ²⁾Odi Nurdiawan, ³⁾Arif Rinaldi Dikananda,
⁴⁾Faturrohman

ABSTRAK

Penelitian ini mengevaluasi kinerja model YOLOv8 dalam mendeteksi pola candlestick secara otomatis dari citra grafik keuangan. Pendekatan kuantitatif eksperimental digunakan dengan dataset 4.435 citra candlestick yang telah dianotasi dari Roboflow Universe. Model dilatih menggunakan konfigurasi standar YOLOv8 dengan learning rate 0.01, batch size 16, dan 100 epoch. Metrik evaluasi meliputi precision, recall, F1-score, dan mean Average Precision (mAP) pada rentang IoU [0.5:0.95]. Hasil menunjukkan YOLOv8 mencapai akurasi deteksi tinggi dengan precision 0.877, recall 0.898, dan mAP@[0.5:0.95] sebesar 0.903. Model menunjukkan kinerja kuat pada pola dengan ciri visual jelas seperti Bullish Engulfing dan Three Line Strike. Namun, tantangan sistematis muncul dalam membedakan pola dengan kemiripan visual tinggi, khususnya Morning Star–Morning Doji Star dan Evening Star–Evening Doji Star. Confusion matrix ternormalisasi mengungkapkan, model juga mampu membedakan pola yang mirip dengan hasil tertinggi 78% pada pola morning star dan nilai terendah 46% pada pola evening doji star, menunjukkan ambiguitas visual yang melekat pada representasi candlestick. Penelitian ini memberikan benchmark komprehensif untuk YOLOv8 dalam deteksi objek finansial dan menekankan perlunya peningkatan fitur berbasis konteks semantik untuk pasangan pola yang membingungkan.

Kata Kunci

Pola Candlestick; YOLOv8; Deep Learning; Analisis Teknikal; Deteksi Objek;

AFILIASI

Prodi, Fakultas
Nama Institusi
Alamat Institusi

^{1,2,3,4)} Program Studi Teknik Informatika.
^{1,2,3,4)} Sekolah Tinggi Manajemen Informatika dan Komputer IKMI Cirebon.
^{1,2,3,4)} Jl. Perjuangan No.10B, Karyamulya, Kec. Kesambi, Kota Cirebon, Jawa Barat 45135.

KORESPONDENSI

Penulis
Email

Maulana Manhur
maulmsshr@gmail.com

LICENSE



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).

I. PENDAHULUAN

Perkembangan teknologi computer vision dan deep learning telah merevolusi analisis data keuangan, khususnya dalam pengenalan pola candlestick sebagai metode analisis teknikal [1]. Transformasi digital di sektor keuangan telah mempercepat adopsi algoritma canggih untuk analisis pasar, mendorong efisiensi dan objektivitas dalam pengambilan keputusan investasi [2]. Teknologi deep learning, khususnya arsitektur berbasis convolutional neural networks (CNN), telah membuka peluang baru dalam pengolahan data visual yang kompleks, memungkinkan sistem untuk mengenali pola yang sebelumnya hanya dapat diidentifikasi oleh analis manusia yang berpengalaman [3]. Identifikasi pola secara manual rentan terhadap bias subjektif dan kesalahan persepsi visual, sehingga diperlukan solusi otomatis yang objektif dan efisien. Karakteristik pasar keuangan yang dinamis dan tidak linear menghasilkan variasi bentuk pola yang luas, menuntut sistem deteksi yang robust terhadap deformasi dan noise, serta mampu mengadaptasi diri dengan perubahan kondisi pasar [4]. Ketidakseimbangan kelas dalam dataset candlestick dan variasi temporal yang tinggi semakin menambah kompleksitas pengembangan model yang dapat menggeneralisasi dengan baik across berbagai kondisi pasar [5].

Penelitian sebelumnya telah mengeksplorasi berbagai arsitektur YOLO untuk deteksi pola candlestick dengan hasil bervariasi. Prasetya & Atastina menggunakan YOLOv5 untuk pola double top dan double bottom dengan akurasi mAP 75,9%, mengonfirmasi efektivitas pendekatan object detection dalam konteks analisis teknikal, meskipun belum menguji YOLO generasi terbaru pada pola yang memiliki kemiripan visual tinggi [6]. Chen & Tsai mengintegrasikan Gramian Angular Field (GAF) dengan modifikasi YOLO-v1, sehingga mampu melakukan klasifikasi sekaligus lokalisasi pola candlestick secara dinamis dengan akurasi klasifikasi 88,35% [7]. Namun, evaluasi komprehensif terhadap YOLOv8 masih terbatas, khususnya dalam konteks pola dengan kemiripan visual ekstrem seperti Evening Star dan Evening Doji Star [8], [9]. Platform Ultralytics telah menjadi standar industri untuk implementasi model YOLO modern dengan berbagai keunggulan seperti API yang intuitif, dukungan mixed precision untuk efisiensi komputasi, integrasi cloud untuk monitoring real-time, serta builtin augmentations yang dapat dikonfigurasi untuk meningkatkan generalisasi model [10].

Penelitian ini bertujuan mengevaluasi kinerja YOLOv8 dalam mendeteksi pola candlestick menggunakan metrik evaluasi standar yang direkomendasikan dalam literatur computer vision, termasuk precision, recall, F1-score, serta mean Average Precision (mAP) pada rentang IoU 0.5 hingga 0.95. Analisis mendalam akan dilakukan terhadap kemampuan model dalam membedakan pola yang secara morfologis hampir identik, dengan pola yang memiliki tingkat kemiripan visual tinggi namun makna prediktif yang sama dalam analisis teknikal. Evaluasi komprehensif ini diharapkan dapat memberikan benchmark empiris yang berharga bagi pengembangan sistem analisis teknikal otomatis yang lebih andal dan akurat, sekaligus mengisi kesenjangan penelitian mengenai performa arsitektur deteksi objek modern dalam domain keuangan visual yang complex dan nuanced [11].

II. METODE PENELITIAN

Dataset terdiri dari 4.435 citra candlestick dari Roboflow Universe dengan lisensi CC BY 4.0, mencakup 10 kelas pola lengkap yaitu: Advance Block, Evening Doji Star, Evening Star, Hikkake Pattern, Morning Doji Star, Morning Star, Three Inside Up-Down, Three Line Strike, Three Outside Up-Down, dan Upside-Downside Gap Three Methods [2]. Data telah di-resize ke resolusi 640×640 piksel dan dianotasi dalam format YOLO (class, x_center, y_center, width, height). Pemeriksaan awal menunjukkan dataset memiliki distribusi kelas yang seimbang dengan frekuensi kemunculan tertinggi pada pola Three Line Strike (18,2%) dan terendah pada pola Upside-Downside Gap Three Methods (7,5%) [3]. Seluruh citra memiliki resolusi seragam 640×640 piksel sesuai spesifikasi input YOLOv8 untuk memastikan optimalisasi ekstraksi fitur dan kompatibilitas dengan arsitektur model. Dataset ini dipilih karena memiliki anotasi profesional, variasi visual yang memadai, dan dokumentasi yang transparan, sehingga meningkatkan validitas internal dan reproducibility penelitian.


Model YOLOv8 diimplementasikan menggunakan framework Ultralytics versi 8.2.0 yang menyediakan pipeline end-to-end untuk pelatihan, validasi, dan inferensi model deteksi objek [8]. Keunggulan utama platform ini meliputi API yang konsisten untuk kemudahan implementasi, dukungan mixed precision melalui Automatic Mixed Precision (AMP) untuk efisiensi komputasi [5], integrasi cloud melalui Ultralytics HUB untuk monitoring training secara real-time [10], serta builtin augmentations yang dapat dikonfigurasi melalui file YAML untuk meningkatkan generalisasi model [12].

Penelitian ini melakukan evaluasi kinerja model YOLOv8 secara eksklusif pada subset validasi internal tanpa memisahkan test set eksternal. Pendekatan ini diadopsi karena dataset Roboflow Universe telah melalui proses anotasi profesional dan pembagian data secara acak oleh penyedia, sehingga subset validasi dianggap representatif dan memadai untuk evaluasi internal [3]. Dalam praktik penelitian object detection modern, evaluasi pada validasi internal merupakan standar umum ketika ground truth pada test set tidak tersedia secara publik [2]. Selain itu, pendekatan ini memungkinkan analisis kesalahan yang transparan dan mendalam, karena seluruh prediksi dapat diverifikasi langsung terhadap label yang tersedia

Kinerja dievaluasi menggunakan metrik standar deteksi objek: precision, recall, F1-score, serta mean Average Precision (mAP) pada rentang IoU 0.5 hingga 0.95 [10]. Analisis kesalahan dilakukan melalui confusion matrix absolut dan normalisasi untuk mengidentifikasi pola kesalahan pada kelas yang mirip secara visual, khususnya pada pasangan pola Evening Star–Evening Doji Star dan Morning Star–Morning Doji Star [12].


III. HASIL DAN PEMBAHASAN

Model YOLOv8 pada pelatihan 100 epoch menggunakan optimizer AdamW, yang menghasilkan performa terbaik pada epoch ke-95 dengan nilai mAP 90.3% dan stabilitas pelatihan yang konsisten. Konfigurasi ini selanjutnya digunakan sebagai dasar untuk evaluasi komprehensif model. Dengan konfigurasi optimal tersebut, model YOLOv8 mencapai performa tinggi dengan precision 0.877, recall 0.898, dan mAP@[0.5:0.95] 0.903, menunjukkan kemampuan deteksi yang sangat baik dalam mengidentifikasi pola candlestick secara akurat dan konsisten.




Gambar 1. Kurva training dan validation loss

Kurva training dan validation loss pada Gambar 1 menunjukkan konvergensi stabil tanpa indikasi overfitting, dengan titik optimal tercapai pada epoch ke-95.



Gambar 2. Precision–Recall Curve dengan AUC 0.903

Precision-Recall curve pada Gambar 2 menunjukkan AUC 0.903, mengindikasikan keseimbangan optimal antara presisi dan recall.




Gambar 3. F1–Confidence Curve

Berdasarkan Gambar 3, F1-score maksimum 0.88 dicapai pada confidence threshold 0.507, menegaskan stabilitas model dalam berbagai ambang keputusan.

Tabel 1 Metrik evaluasi model YOLOv8 pada checkpoint terbaik

Precision	0.877
Recall	0.898
mAP@0.5	0.903
mAP@[0.5:0.95]	0.903

Pada Tabel 1 merangkum metrik evaluasi utama pada checkpoint terbaik, menunjukkan performa yang konsisten antara berbagai metrik evaluasi. Model menunjukkan kemampuan deteksi yang akurat pada pola dengan karakteristik visual kuat seperti Evening Star dan Three Line Strike, namun mengalami kesulitan pada pola dengan tingkat kemiripan visual tinggi seperti Morning Star dan Morning Doji Star [12].




Gambar 1. Confusion Matrix Normalized

Berdasarkan grafik Confusion matrix pada gambar 4 mengungkapkan tantangan utama model dalam membedakan pola dengan kemiripan visual tinggi. Hasil terburuk terjadi pada pasangan Evening Star–Evening Doji Star dan Morning Star–Morning Doji Star. Analisis mendalam menunjukkan: Evening Star mencapai akurasi 66%, dengan 49% kesalahannya menuju Evening Doji Star; Evening Doji Star hanya memiliki akurasi 46%, dengan 22% prediksinya salah ke Evening Star; Morning Star mencapai 78% akurasi, dengan 38% kesalahan menuju Morning Doji Star; Morning Doji Star terdeteksi benar 60%, dengan 20% kesalahan menuju Morning Star.

Perbedaan utama antara Evening Star dan Evening Doji Star terletak pada bentuk candle tengah: Evening Star memiliki body kecil yang jelas, sementara Evening Doji Star menampilkan candle doji yang mencerminkan keraguan pasar ekstrem [9]. Dalam representasi citra 640×640 piksel, perbedaan visual ini sering tidak cukup jelas untuk dideteksi secara konsisten oleh model YOLOv8 [13]. Temuan ini selaras dengan Li et al. dan Uzun et al. yang menunjukkan bahwa pola berbasis candle doji rentan kesalahan klasifikasi karena perbedaan visual yang sangat halus [9], [13].

Dari perspektif analisis teknikal, kesalahan antara pola seperti Evening Star dan Evening Doji Star memiliki implikasi semantik yang berbeda. Pola Doji Star umumnya dianggap sinyal reversal yang lebih kuat karena mencerminkan keraguan ekstrem di puncak atau dasar tren, sedangkan versi non-doji-nya menunjukkan kelelahan momentum yang lebih moderat [9]. Namun, dalam praktik trading, banyak analis memperlakukan keduanya sebagai sinyal reversal setara, sehingga dampak operasional kesalahan klasifikasi ini mungkin tidak kritis selama sistem tidak mengklasifikasikan pola reversal sebagai pola continuation. Hal ini menunjukkan bahwa evaluasi sistem deteksi pola candlestick sebaiknya tidak hanya berfokus pada akurasi visual, tetapi juga mempertimbangkan konteks fungsional dan hierarki semantik pola. Pendekatan ini akan lebih relevan jika sistem diintegrasikan ke dalam alur keputusan investasi nyata [1].



Gambar 2 Contoh hasil deteksi pola candlestick

Contoh hasil deteksi pola candlestick oleh YOLOv8 ditunjukkan pada Gambar 5, menggambarkan model mampu mengidentifikasi objek dengan akurat pada berbagai kondisi latar belakang, variasi skala, dan densitas candle. Kinerja terbaik diperoleh pada pola dengan karakteristik visual kuat, sedangkan kinerja menurun pada pola dengan tingkat kemiripan visual tinggi [14].

IV. SIMPULAN

YOLOv8 menunjukkan kinerja deteksi yang sangat baik untuk pola candlestick dengan $mAP@[0.5:0.95]$ mencapai 0.903. Namun, kemampuan model dalam membedakan pola dengan kemiripan visual ekstrem seperti Evening Star dan Evening Doji Star masih terbatas. Confusion matrix mengungkapkan, model juga mampu membedakan pola yang mirip dengan hasil tertinggi 78% pada pola morning star dan nilai terendah 46% pada pola evening doji star, menunjukkan adanya ambiguitas visual yang inheren pada representasi candlestick [13]. Temuan ini mengkonfirmasi bahwa batasan utama deteksi pola candlestick berbasis citra bukan hanya pada arsitektur model, tetapi lebih pada karakteristik visual pola itu sendiri yang memiliki perbedaan mikro subtil.

Penelitian ini memiliki dua keterbatasan utama. Pertama, evaluasi tidak mencakup data pasar nyata atau chart dari platform trading seperti TradingView, sehingga generalisasi ke kondisi operasional belum teruji. Kedua, penelitian tidak melibatkan backtesting atau simulasi trading untuk mengukur dampak keputusan deteksi terhadap profitabilitas.

Penelitian lanjutan disarankan mengintegrasikan sistem ini dengan mesin trading simulasi guna mengukur nilai praktisnya secara kuantitatif. Pengembangan pendekatan multimodal yang menggabungkan representasi visual dengan data numerik OHLC, atau penerapan enhancement fitur spasial seperti attention mechanism dan CLAHE untuk memperjelas detail candle [5]. Integrasi konteks temporal juga dapat meningkatkan kemampuan model dalam membedakan pola yang secara visual mirip tetapi memiliki makna berbeda dalam analisis teknikal [15]. Evaluasi menggunakan metrik baru yang peka terhadap high-confusion pairs seperti pairwise confusion rate atau semantic-aware mAP disarankan untuk memberikan gambaran lebih akurat tentang kemampuan model [16].

REFERENSI

- [1] S. Birogul, G. Temur, and U. Kose, "YOLO Object Recognition Algorithm and 'Buy-Sell Decision' Model over 2D Candlestick Charts," *IEEE Access*, vol. 8, pp. 91894–91915, 2020, doi: 10.1109/ACCESS.2020.2994282.
- [2] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, "YOLOv4: Optimal Speed and Accuracy of Object Detection," Apr. 2020, [Online]. Available: <http://arxiv.org/abs/2004.10934>
- [3] R. Padilla, W. L. Passos, T. L. B. Dias, S. L. Netto, and E. A. B. Da Silva, "A comparative analysis of object detection metrics with a companion open-source toolkit," *Electronics (Switzerland)*, vol. 10, no. 3, pp. 1–28, Feb. 2021, doi: 10.3390/electronics10030279.
- [4] M. Liang, S. Wu, X. Wang, and Q. Chen, "A stock time series forecasting approach incorporating candlestick patterns and sequence similarity," *Expert Syst Appl*, vol. 205, Nov. 2022, doi: 10.1016/j.eswa.2022.117595.
- [5] "Huang (2022) Fast Candlestick Patterns Detection with Limited Training Samples".
- [6] S. Menggunakan, A. Yolo, and G. A. Prasetya, "Pendeteksi Pola Candlestick Chart Pada."
- [7] J.-H. Chen and Y.-C. Tsai, "Dynamic Deep Convolutional Candlestick Learner," Jan. 2022, [Online]. Available: <http://arxiv.org/abs/2201.08669>
- [8] C.-Y. Wang, A. Bochkovskiy, and H.-Y. M. Liao, "YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors," Jul. 2022, [Online]. Available: <http://arxiv.org/abs/2207.02696>
- [9] I. Uzun, M. Lobachev, V. Kharchenko, T. Schöler, and I. Lobachev, "Candlestick Pattern Recognition in Cryptocurrency Price Time-Series Data Using Rule-Based Data Analysis Methods," *Computation*, vol. 12, no. 7, pp. 1–22, 2024, doi: 10.3390/computation12070132.
- [10] P. Foret, A. Kleiner, H. Mobahi, and B. Neyshabur, "Sharpness-Aware Minimization for Efficiently Improving Generalization," Apr. 2021, [Online]. Available: <http://arxiv.org/abs/2010.01412>
- [11] E. Mienye, N. Jere, G. Obaido, I. D. Mienye, and K. Aruleba, "Deep Learning in Finance: A Survey of Applications and Techniques," Dec. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/ai5040101.
- [12] T. D. Nguyen, Q. B. Tran, D. A. Tran, T. D. Than, and Q. D. Tran, "Object Detection Approach for Stock Chart Patterns Recognition in Financial Markets," in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Feb. 2023, pp. 150–158. doi: 10.1145/3587828.3587851.
- [13] X. Li, Q. Liu, Y. Hu, and H. Liu, "The Double-Layer Clustering Based on K-Line Pattern Recognition Based on Similarity Matching," *Information (Switzerland)*, vol. 15, no. 12, Dec. 2024, doi: 10.3390/info15120821.
- [14] S. Vijayababu, S. Bennur, and S. Vijayababu, "Enhancing Financial Chart Analysis: Advanced Detection of Candlestick Patterns Using Deep Learning Models for Mastering Trend Recognition." [Online]. Available: <https://www.researchgate.net/publication/376685209>
- [15] S. Goutte, H.-V. Le, F. Liu, and H.-J. von Mettenheim, "Deep learning and technical analysis in cryptocurrency market," *Financ Res Lett*, vol. 54, p. 103809, 2023, doi: <https://doi.org/10.1016/j.frl.2023.103809>.
- [16] M. Schubert *et al.*, "Identifying Label Errors in Object Detection Datasets by Loss Inspection."