

Implementasi YOLOv5 untuk Deteksi Objek Mesin EDC: Evaluasi dan Analisis

Rizki Hesnananda¹, Irma Ayu Noviani², Muhammad Zulfariansyah³

¹Teknologi Informasi, Universitas Siber Indonesia, hessananda@cyber-univ.ac.id

²Sistem dan Teknologi, Universitas Siber Indonesia, irma.ayu.noviani@cyber-univ.ac.id

³Teknik Informatika, Nahdlatul Ulama Kalimantan Timur, zulfariansyah@unukaltim.ac.id

Keywords:

Object Detection,
YOLOv5,
Electronic Data Capture (EDC),
Machine Learning,
Transaction Security

ABSTRACT

The Electronic Data Capture (EDC) machine is essential for facilitating non-cash transactions, yet its efficient detection remains a challenge. This study explores the implementation of the You Only Look Once (YOLOv5) algorithm to enhance EDC machine detection. The objective is to improve accuracy and efficiency in detecting EDC machines in various environments, thereby enhancing transaction security and efficiency. The research methodology involved acquiring a diverse dataset from social media platforms and the internet, comprising 396 images after augmentation. Using Roboflow, the dataset was annotated and divided into training, validation, and testing sets. The YOLOv5 model was trained on Google Colab, achieving a Precision of 97.1%, Recall of 86.4%, and mean Average Precision (mAP50) of 92.0% on the validation set. The results demonstrate that YOLOv5 effectively detects EDC machines with high accuracy across different scenarios, validating its robustness in real-world applications. This research suggests that YOLOv5 can significantly improve transaction security and efficiency in retail and service industries. The implications of this research are substantial for industry stakeholders and decision-makers, offering a reliable solution to enhance transaction security and streamline non-cash payment processes. By integrating YOLOv5, businesses can optimize operational efficiency and customer service, paving the way for broader adoption of advanced computer vision technologies in commercial applications.

Kata Kunci

Deteksi Objek
YOLOv5,
Perekam Data Elektronik (EDC),
Pembelajaran Mesin,
Keamanan Transaksi

ABSTRAK

Mesin Perekam Data Elektronik (EDC) merupakan bagian penting dalam memfasilitasi transaksi non-tunai, namun deteksinya masih menjadi tantangan. Pada penelitian ini dilakukan implementasi algoritma You Only Look Once (YOLOv5) untuk meningkatkan deteksi mesin EDC. Tujuannya adalah untuk meningkatkan akurasi dan efisiensi dalam mendeteksi mesin EDC di berbagai lingkungan, sehingga meningkatkan keamanan dan efisiensi transaksi. Metodologi penelitian melibatkan akuisisi dataset yang beragam dari platform media sosial dan internet, terdiri dari 396 citra setelah dilakukan augmentasi. Menggunakan Roboflow, dataset diannotasi dan dibagi menjadi set pelatihan, validasi, dan pengujian. Model YOLOv5 dilatih di Google Colab, mencapai Presisi 97.1%, Recall 86.4%, dan mean Average Precision (mAP50) 92.0% pada set validasi. Hasil penelitian menunjukkan bahwa YOLOv5 efektif mendeteksi mesin EDC dengan akurasi tinggi di berbagai skenario, validasi kekokohnya dalam aplikasi dunia nyata. Penelitian ini menyarankan bahwa YOLOv5 dapat signifikan meningkatkan keamanan transaksi dan efisiensi dalam industri ritel dan layanan. Implikasi dari penelitian ini sangat penting bagi pemangku kepentingan industri dan pengambil keputusan, menawarkan solusi yang handal untuk meningkatkan keamanan transaksi dan menyederhanakan proses pembayaran non-tunai. Dengan mengintegrasikan YOLOv5, bisnis dapat mengoptimalkan efisiensi operasional dan layanan pelanggan, membuka jalan bagi adopsi teknologi visi komputer canggih dalam aplikasi komersial.

Korespondensi Penulis:

Rizki Hesnananda,
Universitas Siber Indonesia, Jalan TB Simatupang no. 6,
Tanjung Barat, Jakarta Selatan, Jakarta.
Telepon : +6282191426369
Email: hessananda@cyber-univ.ac.id

Submitted : 09-07-2024; Accepted : 19-07-2024;
Published : 21-07-2024

Copyright (c) 2024 The Author (s) This article is distributed
under a Creative Commons Attribution-ShareAlike 4.0
International License (CC BY-SA 4.0)

1. PENDAHULUAN

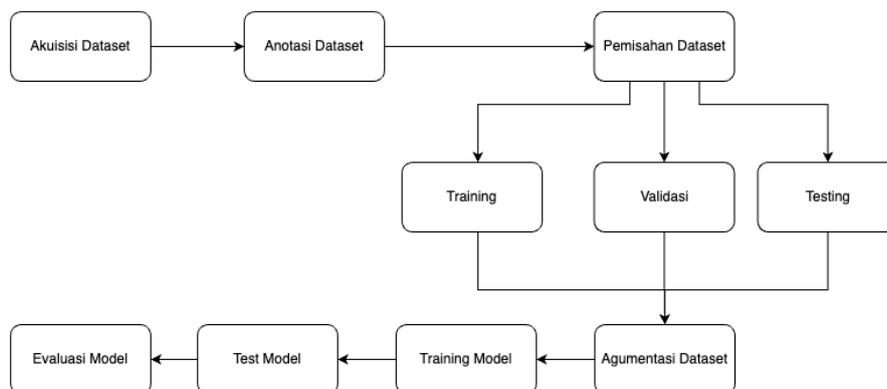
Di era digital ini, metode pembayaran non-tunai semakin banyak digunakan oleh masyarakat. Salah satu perangkat utama yang mendukung transaksi non-tunai adalah mesin *Electronic Data Capture* (EDC). Mesin EDC memungkinkan *merchant* untuk menerima pembayaran dari pelanggan menggunakan kartu kredit, kartu debit, kartu *prepaid*, dan QRIS. Mesin ini dilengkapi dengan pemindai yang membaca strip magnetik atau chip pada kartu dan mengirimkan informasi pembayaran ke bank penerbit kartu secara real-time [1][2][3]. Penggunaan mesin EDC memberikan berbagai manfaat, baik bagi penjual maupun pembeli. Bagi penjual, mesin ini mempercepat proses transaksi, mengurangi risiko kesalahan perhitungan, dan meningkatkan keamanan transaksi dengan teknologi PIN dan chip [4][5][6]. Bagi pembeli, mesin EDC menawarkan kemudahan pembayaran tanpa perlu membawa uang tunai. Oleh karena itu, keberadaan mesin EDC menjadi sangat krusial dalam berbagai sektor bisnis seperti toko, restoran, dan layanan lainnya [7][8][9].

Namun, seiring dengan meningkatnya penggunaan mesin EDC, muncul kebutuhan untuk meningkatkan efisiensi dan keamanan dalam proses identifikasi dan pemantauan mesin ini. Masalah keamanan dalam penggunaan mesin EDC termasuk risiko pencurian atau hilangnya perangkat, yang dapat mengakibatkan kerugian finansial bagi *merchant* dan pelanggan. Selain itu, mesin EDC yang hilang atau disalahgunakan bisa menjadi alat untuk transaksi *fraud*, membahayakan data dan keamanan transaksi non-tunai. Oleh karena itu, deteksi objek mesin EDC diperlukan untuk memantau dan memastikan keberadaan serta keamanan perangkat ini dalam operasional sehari-hari. Salah satu solusi yang dapat diimplementasikan adalah menggunakan teknologi deteksi objek [10][11][12]. Deteksi objek yang akurat dan efisien dapat membantu dalam memantau dan memastikan mesin EDC berfungsi dengan baik, mendeteksi potensi kerusakan, dan meningkatkan keamanan transaksi [13] [14][15]. Dalam konteks ini, metode *You Only Look Once* (YOLO) menjadi salah satu pilihan yang menjanjikan. YOLO adalah algoritma deteksi objek yang dikenal karena kemampuannya untuk melakukan deteksi secara real-time dengan akurasi tinggi [16][17]. Versi terbaru dari algoritma ini, YOLOv5, dipilih untuk penelitian ini karena beberapa alasan utama. YOLOv5 menawarkan kecepatan dan akurasi yang lebih tinggi dibandingkan versi sebelumnya seperti YOLOv3 [18]. Studi menunjukkan bahwa YOLOv5 dapat mendeteksi objek dengan tingkat Recall dan Precision yang lebih tinggi serta memiliki tingkat *False Positive Rate* yang lebih rendah [19]. Dalam konteks deteksi mesin EDC, kemampuan YOLOv5 untuk mengenali objek dengan cepat dan akurat sangat penting mengingat kebutuhan untuk menjaga efisiensi dan keamanan transaksi non-tunai [20][21].

Dataset yang digunakan dalam penelitian ini dikumpulkan dari berbagai platform sosial media seperti *Facebook*, *Twitter*, *Instagram*, dan *Google*, untuk memastikan representativitas yang tinggi [22]. Proses augmentasi data dilakukan untuk meningkatkan jumlah dan variasi citra dalam *dataset*, sehingga model dapat belajar mengenali objek dalam berbagai kondisi [23]. Proses pelatihan model dilakukan menggunakan framework *PyTorch* dengan platform *Google Colaboratory* untuk memanfaatkan kecepatan komputasi yang dibutuhkan [24]. Tujuan dari penelitian ini adalah untuk mengembangkan sistem deteksi objek yang efektif dan efisien untuk mesin EDC, yang dapat meningkatkan keamanan dan kenyamanan transaksi non-tunai. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang teknologi deteksi objek dan aplikasi praktisnya dalam sektor bisnis.

2. METODE PENELITIAN

Pada bagian ini akan dibahas metode yang digunakan untuk mengimplementasikan deteksi objek menggunakan YOLO (*You Only Look Once*) pada citra Mesin Electronic Data Capture (EDC). Tahapan penelitian meliputi proses akuisisi citra hingga evaluasi model YOLOV5. Alur dari tiap tahapan dapat dilihat pada Gambar 1.



Gambar 1. Metode Penelitian

Adapun penjelasan tentang langkah-langkah penelitian ini yaitu:

2.1 Akuisisi Dataset

Data dikumpulkan dari berbagai sumber online, termasuk platform media sosial seperti *Facebook*, *Twitter*, *Instagram*, dan *Google*. Pengumpulan data dilakukan untuk memastikan representativitas yang tinggi dan keberagaman kondisi pengambilan citra mesin *Electronic Data Capture (EDC)*.

2.2 Anotasi Dataset

Setelah data dikumpulkan, dilakukan proses anotasi untuk menandai lokasi objek mesin EDC dalam setiap citra. Anotasi dilakukan secara manual menggunakan alat anotasi seperti *LabelImg*, dengan menggunakan *bounding box* untuk menandai area objek. Proses anotasi ini, bersama dengan pemisahan dataset dan augmentasi, dilakukan menggunakan platform *Roboflow*.

2.3 Pemisahan Dataset

Untuk Dataset yang telah dianotasi dibagi menjadi tiga subset: training set, validation set, dan testing set. Pembagian dilakukan dengan rasio 70% untuk training, 20% untuk validasi, dan 10% untuk testing, untuk memastikan model dapat belajar dan diuji secara efektif. Pemisahan dataset ini juga dilakukan menggunakan platform *Roboflow*.

2.4 Augmentasi Dataset

Proses augmentasi data dilakukan untuk meningkatkan jumlah dan variasi citra dalam dataset. Teknik augmentasi seperti *flipping* dan *rotation* diterapkan untuk menciptakan variasi dari dataset yang ada, membantu model belajar mengenali objek dalam berbagai kondisi pengambilan citra. Proses augmentasi ini dilakukan menggunakan platform *Roboflow*.

2.5 Pelatihan Model YOLO

Proses pelatihan model menggunakan YOLOv5 dilakukan dengan framework *PyTorch* pada platform *Google Colaboratory*. Model dilatih dengan dataset training melalui sejumlah epoch untuk mengoptimalkan parameter-parameter internalnya. Seluruh proses training dijalankan menggunakan bahasa pemrograman *Python*.

2.6 Test Model

Setelah pelatihan selesai, model diuji menggunakan dataset testing untuk mengevaluasi performanya. Dataset testing digunakan untuk menilai akurasi model dalam mendeteksi mesin EDC pada data yang belum pernah dilihat sebelumnya. Proses testing ini juga dilakukan menggunakan *Python* dan dijalankan pada *Google Colab*.

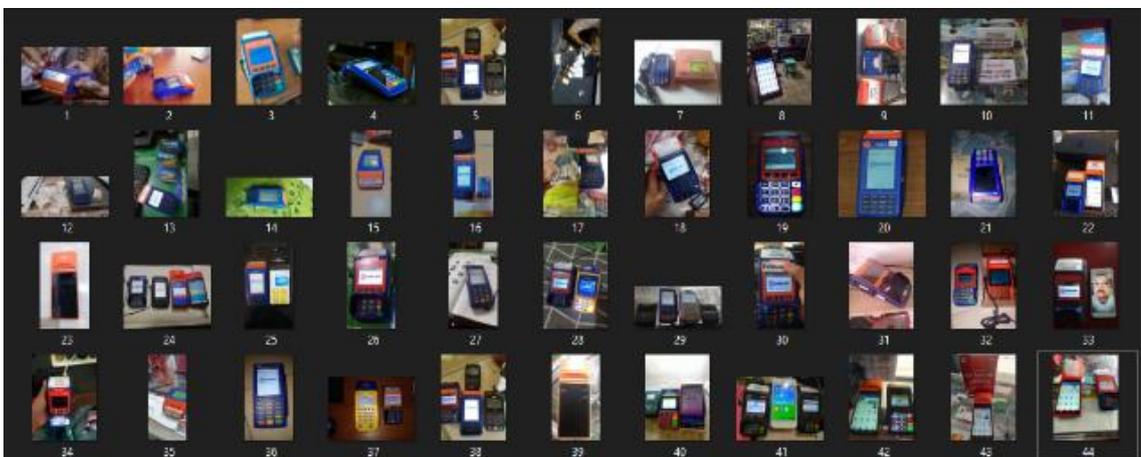
2.7 Evaluasi Model

Langkah terakhir adalah evaluasi model, di mana performa model diukur menggunakan metrik evaluasi seperti *Precision*, *Recall*, dan mean *Average Precision (mAP)*. Evaluasi ini memberikan gambaran tentang seberapa baik model YOLOv5 dapat mendeteksi objek dengan tingkat akurasi yang memuaskan. Evaluasi model dilakukan menggunakan *Python* dan dijalankan pada *Google Colab*.

3. HASIL DAN ANALISIS

3.1 Akuisisi Dataset

Proses akuisisi data merupakan langkah pertama yang krusial dalam penelitian ini. Data dikumpulkan dari berbagai platform media sosial seperti *Facebook*, *Twitter*, *Instagram*, dan *Google*. Pemilihan sumber data ini bertujuan untuk memastikan representasi yang baik dari kondisi nyata di mana mesin EDC digunakan. Total 164 citra asli dikumpulkan pada tahap awal penelitian ini. Variasi citra yang diambil mencakup berbagai kondisi pencahayaan, sudut pandang, dan latar belakang untuk memberikan data yang kaya dan beragam bagi model deteksi. Gambar 2 menunjukkan beberapa contoh citra yang dikumpulkan selama proses akuisisi data.



Gambar 2. Contoh Dataset

Setelah pengumpulan, citra-citra tersebut disusun dan disiapkan untuk proses anotasi lebih lanjut. Kualitas dan keragaman data yang dikumpulkan sangat penting untuk memastikan bahwa model yang akan dilatih dapat mengenali mesin EDC dalam berbagai situasi yang mungkin ditemui di lapangan.

3.2 Anotasi Dataset

Anotasi data dilakukan menggunakan platform *Roboflow*, di mana setiap citra mesin EDC diidentifikasi dan diberi bounding box. Proses ini sangat penting karena anotasi yang akurat membantu model dalam memahami dan mendeteksi lokasi spesifik dari objek yang diinginkan dalam setiap citra. Anotasi dilakukan secara manual untuk memastikan presisi yang tinggi, dengan setiap mesin EDC dalam citra diberi label yang sesuai.



Gambar 3. Memberi Label pada Dataset

Gambar 3 menunjukkan contoh anotasi data yang dilakukan di *Roboflow*. Penggunaan *Roboflow* dalam proses anotasi memungkinkan peneliti untuk dengan mudah mengatur dan mengelola dataset. Platform ini menyediakan antarmuka yang intuitif dan alat yang membantu mempercepat proses anotasi.

3.3 Pemisahan Dataset: Training, Validasi, Testing

Dataset yang telah diannotasi kemudian dibagi menjadi tiga set: training, validasi, dan testing. Pembagian ini dilakukan untuk memastikan bahwa model dapat dilatih dengan baik dan diuji secara efektif. Pembagian dilakukan dengan rasio 70% untuk training, 20% untuk validasi, dan 10% untuk testing. Sehingga dari 164 dataset citra, sebanyak 115 citra digunakan untuk training set, 32 citra untuk validation set, dan 17 citra untuk testing set. Pembagian ini dirancang untuk memberikan data bagi model untuk belajar dan juga untuk menguji kinerja model dengan data yang belum pernah dilihat sebelumnya. Proses pemisahan dataset dilakukan dengan hati-hati untuk memastikan bahwa setiap set memiliki distribusi yang representatif dari seluruh dataset. Hal ini penting untuk menghindari bias dalam pelatihan dan evaluasi model.

3.4 Augmentasi Dataset

Untuk meningkatkan variasi dan jumlah data pelatihan, dilakukan augmentasi dataset. Teknik augmentasi yang digunakan meliputi *flip* dan rotasi citra. *Flip* digunakan untuk menciptakan variasi orientasi citra mesin EDC, sementara rotasi membantu dalam menciptakan variasi posisi objek dalam citra. Proses augmentasi ini meningkatkan jumlah total citra dari 164 menjadi 396. Augmentasi data membantu model untuk lebih mengenali mesin EDC dalam berbagai kondisi dan situasi yang mungkin ditemui di lapangan. Dengan menambahkan variasi, model dapat belajar untuk mengenali pola yang lebih luas dan meningkatkan akurasi deteksi.

3.5 Training Model

Proses *training* model dilakukan menggunakan algoritma *YOLOv5* yang diimplementasikan dalam *framework PyTorch*. Training dijalankan pada platform *Google Colab*, yang menyediakan sumber daya komputasi yang diperlukan untuk proses ini. Model dilatih selama 100 epoch dengan total durasi sekitar 6.669 jam. Selama proses training, model secara bertahap memperbarui parameter internalnya berdasarkan pola yang ditemukan dalam data pelatihan. Gambar 4 menunjukkan proses pelatihan *YOLOv5* menggunakan *Platform Google Colab*.

```

Epoch  GPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
96/99   0G        0.01631  0.01106  0          41         416: 100% 22/22 [03:47<00:00, 10.32s/it]
      Class  Images  Instances  P         R         mAP50  mAP50-95: 100% 1/1 [00:08<00:00, 8.49s/it]
      all    31      44        0.906    0.874    0.891  0.662

Epoch  GPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
97/99   0G        0.01685  0.01166  0          52         416: 100% 22/22 [03:53<00:00, 10.61s/it]
      Class  Images  Instances  P         R         mAP50  mAP50-95: 100% 1/1 [00:08<00:00, 8.27s/it]
      all    31      44        0.922    0.841    0.891  0.669

Epoch  GPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
98/99   0G        0.01672  0.01098  0          47         416: 100% 22/22 [03:50<00:00, 10.50s/it]
      Class  Images  Instances  P         R         mAP50  mAP50-95: 100% 1/1 [00:08<00:00, 8.86s/it]
      all    31      44        0.922    0.841    0.891  0.676

Epoch  GPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
99/99   0G        0.01654  0.01169  0          44         416: 100% 22/22 [03:49<00:00, 10.45s/it]
      Class  Images  Instances  P         R         mAP50  mAP50-95: 100% 1/1 [00:08<00:00, 8.06s/it]
      all    31      44        0.922    0.841    0.891  0.67

100 epochs completed in 6.669 hours.
Optimizer stripped from runs/train/yolov5s_results/weights/last.pt, 14.3MB
Optimizer stripped from runs/train/yolov5s_results/weights/best.pt, 14.3MB

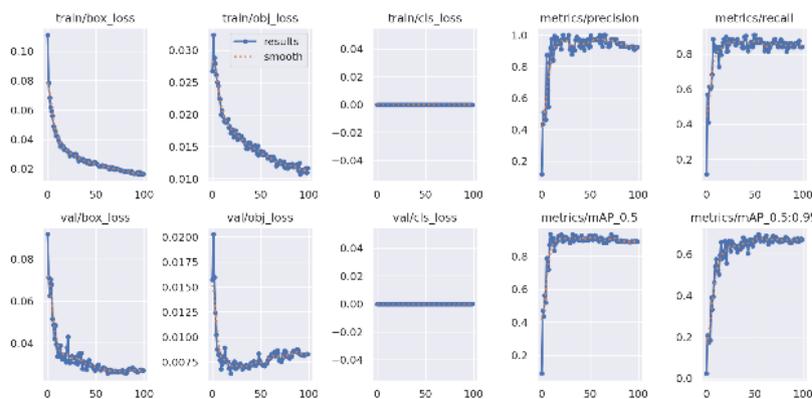
Validating runs/train/yolov5s_results/weights/best.pt...
Fusing layers...
Model summary: 157 layers, 7012822 parameters, 0 gradients, 15.8 GFLOPs
      Class  Images  Instances  P         R         mAP50  mAP50-95: 100% 1/1 [00:09<00:00, 9.95s/it]
      all    31      44        0.971    0.864    0.92  0.697
    
```

Gambar 4. Training Model

Jumlah parameter model mencapai 7,012,822 dengan 157 lapisan. *Training* dilakukan dengan memperhatikan kualitas data dan parameter model untuk mencapai hasil yang optimal.

3.6 Test Model

Setelah model dilatih, tahap berikutnya adalah pengujian model pada data testing set. Proses ini bertujuan untuk mengevaluasi kinerja model dalam mendeteksi mesin EDC pada data yang belum pernah dilihat sebelumnya. Hasil pengujian menunjukkan bahwa model *YOLOv5* mampu mendeteksi mesin EDC dengan presisi tinggi, mencapai *Precision* sebesar 97.1%, *Recall* sebesar 86.4%, dan mean *Average Precision (mAP50)* sebesar 92.0%.



Gambar 5. Grafik loss (box loss, object loss, dan class loss)

Gambar 5 menunjukkan hasil deteksi model pada beberapa contoh citra dalam testing set. Pengujian model memberikan gambaran tentang seberapa baik model dapat menggeneralisasi pengetahuannya dari data *training* ke situasi dunia nyata.

3.7 Evaluasi Model

Evaluasi model dilakukan untuk menilai kinerja model secara keseluruhan. Nilai *mAP50-95*, yang merupakan *mean Average Precision* pada rentang nilai *confidence threshold* antara 50% hingga 95%, mencapai 69.7%. Evaluasi ini menunjukkan bahwa model memiliki performa yang baik dalam mendeteksi mesin EDC dengan berbagai tingkat keyakinan.



Gambar 6. Hasil Uji Model Deteksi

Gambar 6 menunjukkan perbandingan hasil deteksi model pada berbagai tingkat *confidence threshold*. Analisis hasil evaluasi menunjukkan bahwa model *YOLOv5* dapat diandalkan untuk aplikasi deteksi mesin EDC di dunia nyata. Implikasi dari hasil penelitian ini adalah bahwa model dapat digunakan untuk meningkatkan efisiensi dan keamanan dalam transaksi non-tunai.

4. KESIMPULAN

Kesimpulan dari penelitian ini menunjukkan bahwa implementasi metode *You Only Look Once (YOLOv5)* untuk deteksi objek mesin *Electronic Data Capture (EDC)* memberikan hasil yang sangat memuaskan. Model yang dikembangkan berhasil mencapai *Precision* sebesar 97.1%, *Recall* sebesar 86.4%, dan mean *Average Precision (mAP50)* sebesar 92.0% pada data validasi. Hasil ini menegaskan bahwa *YOLOv5* efektif dalam mendeteksi mesin EDC dengan tingkat akurasi yang tinggi, bahkan dalam berbagai kondisi lingkungan yang beragam. Penerapan teknologi ini berpotensi meningkatkan efisiensi dan keamanan transaksi non-tunai di berbagai industri, terutama dalam sektor ritel dan layanan.

Penelitian ini memiliki beberapa batasan yang perlu diperhatikan. Dataset yang digunakan relatif terbatas dalam jumlah dan representasi kondisi nyata. Meskipun augmentasi data telah dilakukan untuk meningkatkan variasi, keberagaman data tetap menjadi faktor penting yang perlu ditingkatkan. Selain itu, penelitian ini hanya menggunakan *YOLOv5* sebagai model deteksi objek, sehingga hasil yang didapatkan belum dapat dibandingkan dengan model atau metode lain yang mungkin memiliki kinerja berbeda dalam konteks yang sama.

Penelitian selanjutnya, disarankan untuk meningkatkan jumlah dan variasi dataset yang digunakan agar model dapat lebih menggeneralisasi kondisi nyata di lapangan. Selain itu, melakukan perbandingan kinerja dengan model deteksi objek lainnya seperti *Faster R-CNN* atau *SSD* dapat memberikan wawasan lebih lanjut mengenai efektivitas berbagai algoritma dalam mendeteksi mesin EDC. Penelitian lanjutan juga dapat mempertimbangkan penggunaan data sintetik untuk lebih memperkaya dataset dan mengeksplorasi teknik augmentasi data yang lebih canggih. Dengan demikian, hasil yang lebih komprehensif dan aplikatif dapat dicapai, memberikan kontribusi yang lebih signifikan bagi industri terkait.

REFERENSI

- [1] E. F. Patridge and T. P. Bardyn, "Research electronic data capture (REDCap)," *J. Med. Libr. Assoc. JMLA*, vol. 106, no. 1, p. 142, 2018.
- [2] E. Weliyanti, M. S. Mahrinasari, and E. Herdrawaty, "Electronic Data Capture (EDC) marketing strategy in an Indonesian state-owned bank," in *The Future Opportunities and Challenges of Business in Digital Era 4.0*, Routledge, 2020, pp. 133–136.
- [3] I. Susanto, "Using field experiments to analyze changes in electronic data capture adoption decisions," *J. INFOTEL*, vol. 14, no. 1, pp. 1–7, 2022.
- [4] D. Ghelani, T. K. Hua, and S. K. R. Koduru, "Cyber security threats, vulnerabilities, and security solutions models in banking," *Authorea Prepr.*, 2022.
- [5] M. E. Fadruddin, S. Rahayu, and D. I. Asiati, "Pengaruh Promosi, Terhadap Keputusan Penggunaan Electronic Data Capture (EDC) Dimediasi Oleh Pengetahuan Dan Kepercayaan Merchant Di PT Bank Negara Indonesia Kantor Cabang Musi Palembang," *Integritas J. Manaj. Prof.*, vol. 1, no. 2, pp. 163–180, 2020.
- [6] S. A. Kristyan, "Business Process for debit card transactions using Electronic Data Capture (EDC) Case study: Bank CIMB Niaga Tbk," *Indones. J. Comput.*, vol. 9, no. 1, pp. 1–8, 2024.

- [7] A. Prastyawan and T. Handriana, "STRATEGI PENCAPAIAN TARGET ELECTRONIC DATA CAPUTERE (EDC) MERCHANT PADA AGEN BINAAN UNIT KERJA BANK X," *Ekonis J. Ekon. dan Bisnis*, vol. 24, no. 1, 2022.
- [8] C. Kuswibowo and N. A. Putri, "Pengaruh Kualitas Pelayanan Menggunakan Mesin Edc Terhadap Kepuasan Merchant Pada Pt Bank Rakyat Indonesia Jakarta Pusat," in *Prosiding Seminar Nasional Manajemen Industri dan Rantai Pasok*, 2020, vol. 1, no. 1, pp. 129–136.
- [9] E. G. Rinadi, "Analisis Pencapaian Target dan Sales Volume Mesin EDC (Electronic Data Capture) Menggunakan Bauran Pemasaran 4P (Product, Price, Place, Promotion) pada Merchant di PT Bank Rakyat Indonesia Kantor Cabang Pembantu Mojosoongo Tahun Periode 2022," 2023.
- [10] P. R. Aningtiyas, A. Sumin, and S. Wirawan, "Pembuatan Aplikasi Deteksi Objek Menggunakan TensorFlow Object Detection API dengan Memanfaatkan SSD MobileNet V2 Sebagai Model Pra-Terlatih: Array," *J. Ilm. Komputasi*, vol. 19, no. 3, pp. 421–430, 2020.
- [11] K. Anwariyah, "Deteksi Objek Kendaraan Pada Citra Kendaraan Bermotor," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 1, no. 4, pp. 311–317, 2020.
- [12] M. F. NURYASIN, C. MACHBUB, and L. YULIANTI, "Kombinasi Deteksi Objek, Pengenalan Wajah dan Perilaku Anomali menggunakan State Machine untuk Kamera Pengawas," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 1, p. 86, 2023.
- [13] F. Wang, N. Yang, P. M. Shakeel, and V. Saravanan, "Machine learning for mobile network payment security evaluation system," *Trans. Emerg. Telecommun. Technol.*, vol. 35, no. 4, p. e4226, 2024.
- [14] M. Arpah and S. D. Nabella, "The Effect of Trust, Perception of Risk and Security on Consumer Purchase Interest in Lazada (Empirical Study on Students of The Faculty of Economics and Business, Ibn Sina University)," *Int. J. Accounting, Manag. Econ. Soc. Sci.*, vol. 1, no. 4, pp. 304–316, 2023.
- [15] S. Agrawal, "Enhancing payment security through AI-Driven anomaly detection and predictive analytics," *Int. J. Sustain. Infrastruct. Cities Soc.*, vol. 7, no. 2, pp. 1–14, 2022.
- [16] S. Hossain, H. Anzum, and S. Akhter, "Comparison of YOLO (V3, V5) and MobileNet-SSD (V1, V2) for Person Identification Using Ear-Biometrics," *Int. J. Comput. Digit. Syst.*, vol. 15, no. 1, pp. 1259–1271, 2024.
- [17] R. Hesnanda, D. Natasya, and N. Wiliani, "Cloth Bag Object Detection Using the Yolo Algorithm (You Only See Once) V5," *J. Pilar Nusa Mandiri*, vol. 18, no. 2, pp. 217–222, 2023.
- [18] A. Kuznetsova, T. Maleva, and V. Soloviev, "YOLOv5 versus YOLOv3 for apple detection," in *Cyber-Physical Systems: Modelling and Intelligent Control*, Springer, 2021, pp. 349–358.
- [19] M. A. Nangin, I. R. G. Barus, and S. Wahyoedi, "The effects of perceived ease of use, security, and promotion on trust and its implications on fintech adoption," *J. Consum. Sci.*, vol. 5, no. 2, pp. 124–138, 2020.
- [20] K. Khairunnas, E. M. Yuniarno, and A. Zaini, "Pembuatan Modul Deteksi Objek Manusia Menggunakan Metode YOLO untuk Mobile Robot," *J. Tek. ITS*, vol. 10, no. 1, pp. A50–A55, 2021.
- [21] D. N. Alfarizi, R. A. Pangestu, D. Aditya, M. A. Setiawan, and P. Rosyani, "Penggunaan Metode YOLO Pada Deteksi Objek: Sebuah Tinjauan Literatur Sistematis," *AI dan SPK J. Artif. Intell. dan Sist. Penunjang Keputusan*, vol. 1, no. 1, pp. 54–63, 2023.
- [22] P. Wspanialy, J. Brooks, and M. Moussa, "An Image Labeling Tool and Agricultural Dataset for Deep Learning," pp. 1–5, 2020.
- [23] J. Nelson, "Image Augmentation," 2021. [Online]. Available: <https://docs.roboflow.com/image-transformations/image-augmentation>. [Accessed: 23-Aug-2021].
- [24] S. Narejo, B. Pandey, D. Esenarro Vargas, C. Rodriguez, and M. R. Anjum, "Weapon Detection Using YOLO V3 for Smart Surveillance System," *Math. Probl. Eng.*, vol. 2021, 2021.