

IMPLEMENTASI YOLOV5 UNTUK DETEKSI KARTU DEBIT: STUDI KASUS PADA KLASIFIKASI BRITAMA DAN SIMPEDES

Rizki Hesanda^{1*}; Vian Firmansyah²

Program Studi Teknologi Informasi¹
Univeristas Siber Indonesia, Jakarta Selatan, Indonesia¹
www.cyber-univ.ac.id¹
hessananda@cyber-univ.ac.id^{1*}

Bank Rakyat Indonesia, Jakarta Selatan, Indonesia ²
www.bri.co.id²
vian.firmansyah1402@gmail.com²
(*) Corresponding Author



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

Abstract— This study aims to develop an object detection model based on YOLOv5 to classify debit card types. With the advancement of financial technology, the need for automated systems to identify debit cards has become essential to enhance transaction efficiency and security. The research methodology involves five main stages: dataset collection, data preprocessing through labeling and resizing to 640 x 640, dataset augmentation, YOLOv5 model training, and model evaluation. The dataset used consists of three categories of debit cards, with a total of 300 images. The results demonstrate that the YOLOv5 model achieves excellent performance with a mean average precision (mAP) of 92.7% and an object loss value of 0.08. The high mAP value indicates the model's capability to accurately recognize objects, while the low object loss value reflects minimal detection errors during testing. In conclusion, YOLOv5 has proven to be reliable for application in debit card detection systems. This study provides significant contributions to the development of automation systems in the financial sector, particularly in improving the efficiency and accuracy of identification processes. It is hoped that this research will serve as a foundation for further studies with broader datasets, the application of more advanced augmentation techniques, and the utilization of more sophisticated hardware to enhance model performance.

Keywords: debit card classification, deep learning, object detection, YOLOv5.

Abstrak— Penelitian ini bertujuan untuk mengembangkan model deteksi objek berbasis YOLOv5 dalam mengklasifikasikan jenis kartu debit. Dengan semakin berkembangnya teknologi keuangan, kebutuhan akan sistem otomatisasi untuk identifikasi kartu debit menjadi penting guna meningkatkan efisiensi dan keamanan transaksi. Metodologi penelitian mencakup lima tahapan utama: pengumpulan dataset, preprocessing data melalui labeling dan resize ke ukuran 640 x 640, augmentasi dataset, pelatihan model YOLOv5, serta evaluasi performa model. Dataset yang digunakan terdiri dari tiga kategori kartu debit, dengan total 300 gambar. Hasil penelitian menunjukkan bahwa model YOLOv5 mampu mencapai kinerja yang sangat baik dengan Mean Average Precision (mAP) sebesar 92,7% dan nilai Object Loss sebesar 0,08. Nilai mAP yang tinggi menunjukkan kemampuan model dalam mengenali objek dengan akurasi tinggi, sedangkan nilai Object Loss yang rendah mencerminkan minimnya kesalahan deteksi selama pengujian. Dapat disimpulkan bahwa YOLOv5 terbukti andal untuk diterapkan dalam sistem deteksi kartu debit. Hasil penelitian ini memberikan kontribusi penting bagi pengembangan sistem otomatisasi di sektor keuangan, terutama dalam meningkatkan efisiensi dan akurasi proses identifikasi. Penelitian ini diharapkan dapat menjadi dasar untuk studi lanjutan dengan cakupan dataset yang lebih luas, penggunaan teknik augmentasi yang lebih kompleks, serta pemanfaatan perangkat keras yang lebih canggih untuk meningkatkan performa model.

Kata kunci: klasifikasi kartu debit, deep learning, deteksi objek, YOLOv5.

PENDAHULUAN

Perkembangan teknologi di era digital saat ini telah mempengaruhi berbagai sektor, termasuk sektor perbankan (Mulyana et al., 2023). Seiring dengan kemajuan teknologi, bank-bank di Indonesia terus berupaya meningkatkan kualitas layanan mereka guna memenuhi kebutuhan nasabah (Iman et al., 2023). Salah satu upaya yang dilakukan adalah dengan menyediakan berbagai jenis kartu debit yang dapat disesuaikan dengan preferensi dan kebutuhan nasabah. Kartu debit ini tidak hanya mempermudah transaksi finansial, namun juga menjadi identitas dari layanan dan program-program khusus yang ditawarkan oleh bank (Jikrillah & Fadah, 2023).

Tren digitalisasi perbankan di Indonesia diperkuat oleh beberapa faktor dan data kunci. Pandemi *Covid-19* mempercepat peralihan dari ekonomi fisik ke ekonomi *virtual*, mendorong transformasi digital sebagai *respons* terhadap perubahan perilaku konsumen. Hal ini menciptakan peluang besar melalui integrasi perbankan ke dalam ekosistem digital, termasuk kemitraan dengan perusahaan teknologi finansial (*fintech*) dan perusahaan teknologi besar (*bigtech*) yang memberikan akses ke data dan inovasi untuk meningkatkan produk serta layanan perbankan. Berdasarkan *penilaian Digital Maturity Assessment for Bank (DMAB)*, tingkat kematangan digital perbankan Indonesia pada dimensi data, teknologi, kolaborasi, dan layanan pelanggan mencapai rata-rata 50%, menunjukkan kemajuan signifikan meskipun belum optimal. Namun, dimensi manajemen risiko dan tata kelola institusi masih berada di bawah 50%, menandakan adanya tantangan dalam membangun organisasi yang lebih adaptif secara digital (PT Bank Mandiri (Persero) Tbk, 2021).

Transformasi ini didukung oleh penggunaan teknologi seperti *Artificial Intelligence*, *Cloud Computing*, dan *Blockchain* yang memungkinkan peningkatan efisiensi operasional serta pengalaman pelanggan berbasis digital. Namun, tantangan seperti perlindungan data, risiko serangan siber, dan kebutuhan akan infrastruktur teknologi yang merata menjadi perhatian utama. Inisiatif regulasi berbasis prinsip (*principle-based*) yang disusun Otoritas Jasa Keuangan (OJK) bertujuan untuk memastikan keseimbangan antara inovasi digital dan aspek prudensial demi menjaga stabilitas perbankan nasional. Data dan strategi ini menunjukkan urgensi percepatan transformasi digital guna memperkuat daya saing perbankan Indonesia di tingkat global (Departemen Penelitian dan Pengaturan Perbankan Otoritas Jasa keuangan, 2021).

Bank Rakyat Indonesia (BRI), sebagai salah satu bank terbesar di Indonesia, menawarkan beberapa jenis kartu debit, antara lain Britama Black, Britama Silver, dan Simpedes (Helfasari et al., 2021). Masing-masing kartu ini memiliki fitur dan manfaat yang berbeda, sehingga penting bagi bank untuk memastikan nasabah mendapatkan kartu yang sesuai dengan kebutuhannya. Dalam proses distribusi dan pelayanan, bank memerlukan sistem yang efektif untuk mengenali dan mengelompokkan jenis kartu debit dengan cepat dan akurat. Hal ini menjadi tantangan tersendiri, terutama di era di mana digitalisasi proses perbankan menjadi semakin krusial (Tristante et al., 2023; Wardhani & Wijaya, 2020).

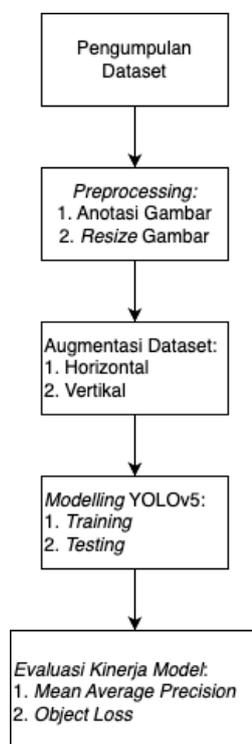
Namun, identifikasi jenis kartu debit secara manual sering kali membutuhkan waktu dan berpotensi terjadi kesalahan. Untuk itu, diperlukan suatu sistem otomatis yang dapat membantu mengenali jenis kartu debit secara cepat dan akurat. Salah satu solusi yang dapat diterapkan adalah dengan memanfaatkan teknologi *Computer Vision* dan *Machine Learning* (Hesananda & Agustian, 2024). Algoritma *You Only Look Once (YOLO)*, khususnya YOLOv5, merupakan salah satu metode deteksi objek yang dapat digunakan untuk mengklasifikasikan jenis kartu debit berdasarkan gambar (Hesananda et al., 2024; Redmon et al., 2016).

Pemilihan YOLOv5 untuk deteksi objek didukung oleh keunggulan performanya dibandingkan versi sebelumnya, seperti YOLOv3. YOLOv5 mencapai tingkat *recall* sebesar 97,2% dan *precision* 96,5%, jauh lebih tinggi dibandingkan YOLOv3 yang hanya memiliki *recall* 90,8% dengan tambahan proses *pra* dan *pasca* pemrosesan. Tanpa proses tambahan, *recall* YOLOv3 bahkan turun drastis menjadi 9,1%, menunjukkan bahwa YOLOv5 menawarkan performa yang jauh lebih baik secara langsung tanpa membutuhkan langkah pemrosesan tambahan. Selain itu, YOLOv5 memiliki *false positive rate (FPR)* yang rendah, yaitu hanya 3,5%, dibandingkan dengan YOLOv3 yang mencapai 7,8%. Kemampuan YOLOv5 untuk memproses gambar secara *real-time* dengan akurasi tinggi, tanpa memerlukan pemrosesan tambahan yang kompleks, menjadikannya pilihan yang sangat tepat untuk tugas seperti klasifikasi kartu debit. Peningkatan pada arsitektur YOLOv5, seperti fitur ekstraksi yang lebih baik dan optimasi untuk dataset yang beragam, semakin memperkuat relevansinya untuk penelitian ini. Keunggulan ini menjadikan YOLOv5 pilihan optimal untuk deteksi objek yang akurat dan efisien, terutama dalam hal aplikasi praktis dengan keterbatasan komputasi (Iyer et al., 2021; Kuznetsova et al., 2021; Yusro et al., 2023).

Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis YOLOv5 untuk mendeteksi jenis kartu debit BRI (Britama Black, Britama Silver, dan Simpedes) dari gambar yang diambil menggunakan kamera *smartphone*. Dengan adanya sistem deteksi otomatis ini, diharapkan bank dapat meningkatkan efisiensi operasional dan mengurangi kesalahan dalam proses identifikasi kartu debit (Arby et al., 2022; Chen & Shiu, 2022; Chethan Kumar et al., 2020; Sarosa et al., 2021). Selain itu, penelitian ini juga akan mengevaluasi performa model dengan menggunakan metrik mean *Average Precision* (mAP) untuk memastikan bahwa sistem yang dikembangkan memiliki akurasi yang memadai untuk diterapkan dalam skenario dunia nyata (Kivrak & Gürbüz, 2022; Nepal & Eslamiat, 2022).

BAHAN DAN METODE

Penelitian ini bertujuan untuk mengembangkan model klasifikasi jenis kartu debit BRI menggunakan algoritma deteksi objek YOLOv5. Tahapan penelitian dilakukan dengan pendekatan berbasis *Machine Learning* yang meliputi pengumpulan *dataset*, *preprocessing*, augmentasi, pelatihan model, hingga evaluasi performa. Pada Gambar 1, ditampilkan tahapan metode penelitian yang dilakukan:



Sumber: Hasil Penelitian, 2024)
Gambar 1. Metode Penelitian

Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari 300 gambar kartu debit yang terbagi menjadi tiga kategori yaitu Kartu Britama Black, Silver dan Simpedes. Proses pengambilan data dilakukan menggunakan kamera *smartphone* dengan resolusi tinggi untuk memastikan kualitas gambar yang baik. Gambar diambil dalam kondisi pencahayaan alami dan buatan untuk mencakup berbagai variasi kondisi lingkungan. Setiap kartu debit difoto dari berbagai sudut dan jarak guna meningkatkan keragaman data. Latar belakang yang digunakan bervariasi, termasuk permukaan polos dan bertekstur, untuk meniru situasi nyata di mana kartu debit mungkin dikenali. Semua gambar disimpan dalam format JPEG untuk menjaga kualitas data.

Preprocessing

Proses *preprocessing* bertujuan untuk mempersiapkan gambar agar sesuai dengan input yang diharapkan oleh model YOLOv5. Langkah-langkah *preprocessing* yang dilakukan meliputi:

1. Anotasi Gambar: Menggunakan format YOLO *annotation* untuk memberikan informasi *bounding box* pada masing-masing gambar.
2. Resize Gambar: semua gambar diubah ukurannya menjadi 640x640 sesuai standar *input* YOLOv5.

Augmentasi Data

Untuk meningkatkan keragaman dataset dan mengurangi risiko *overfitting*, dilakukan augmentasi data dengan teknik *Flipping* yaitu melakukan pembalikan gambar secara horizontal dan vertikal. Augmentasi ini diterapkan secara acak selama proses *training* model untuk memastikan model lebih tahan terhadap variasi data.

Modelling YOLOv5

Tahap ini melibatkan dua sub-proses utama, yaitu:

1. *Training*
Melatih model YOLOv5 menggunakan data *training* untuk mengenali pola dan karakteristik setiap kelas kartu debit. Parameter yang digunakan dijelaskan sebagai berikut:
 - a. *img* 416: Resolusi input gambar diatur sebesar 416 x 416 piksel. Resolusi ini dipilih karena memberikan keseimbangan antara kecepatan pelatihan dan akurasi deteksi, sesuai dengan rekomendasi YOLOv5 untuk perangkat dengan keterbatasan GPU.
 - b. *batch* 16: Ukuran batch ditetapkan sebanyak 16 gambar per iterasi. Pemilihan nilai ini mempertimbangkan kapasitas memori GPU

- yang digunakan (GPU Google Colab dengan spesifikasi dasar), untuk memastikan proses pelatihan berjalan tanpa gangguan.
- c. *epochs* 100: Jumlah *epoch* pelatihan ditetapkan sebanyak 100 untuk memberikan waktu yang cukup bagi model dalam mempelajari pola pada *dataset*. Nilai ini merupakan hasil pertimbangan dari ukuran *dataset* dan kompleksitas tugas deteksi objek.
 - d. *cache*: *Dataset* disimpan dalam memori selama pelatihan untuk mempercepat waktu akses data.

Proses pelatihan dilakukan menggunakan GPU standar Google Colab, yang memungkinkan akselerasi komputasi selama pelatihan. Hasil dari pelatihan ini mencakup bobot model yang terlatih, grafik performa selama pelatihan, dan metrik evaluasi.

2. *Testing*

Menguji performa model dengan data *testing* untuk mengevaluasi kinerja prediksi.

Evaluasi kinerja

Evaluasi kinerja model dilakukan menggunakan dua metrik utama, yaitu:

1. *Mean Average Precision* (mAP)
mAP digunakan untuk mengukur tingkat keberhasilan model dalam mendeteksi dan mengklasifikasikan objek.

2. *Object Loss*

Object loss digunakan untuk mengevaluasi tingkat kesalahan deteksi pada model.

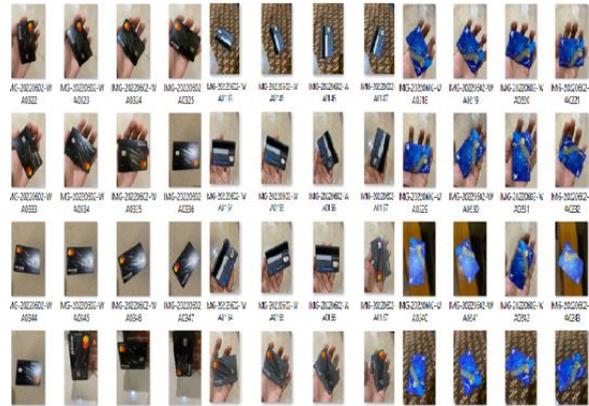
HASIL DAN PEMBAHASAN

Pada bagian ini akan dibahas tentang hasil dari metode penelitian yang telah dilakukan sebagai berikut:

Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini berupa gambar Kartu Debit BRI. Gambar dikumpulkan melalui tangkapan kamera *smartphone* dan dari *google image*. Gambar lalu dikumpulkan dalam satu *folder* seperti pada Gambar 2.

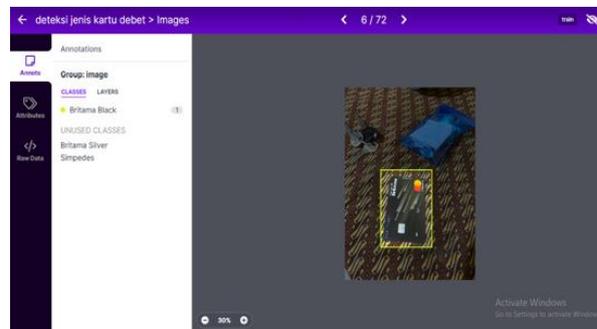
Pada Gambar 2 dapat dilihat kumpulan gambar kartu debit ATM BRI sebanyak 3 jenis yaitu: Britama Black, Britama Silver, dan Simpedes. Gambar kartu britama black dikumpulkan sebanyak 100 gambar. Gambar kartu britama silver dikumpulkan sebanyak 100 gambar.



Sumber: (Hasil Penelitian, 2024)

Gambar 2. Contoh Dataset

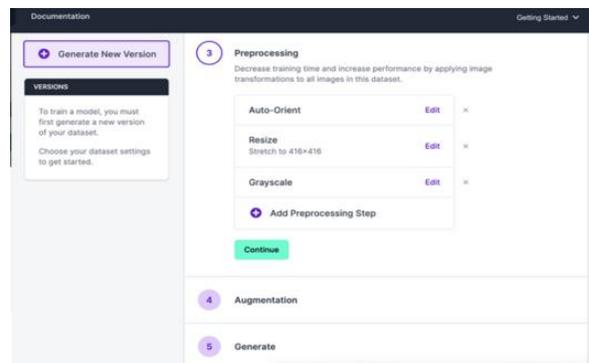
Preprocessing



Sumber: (Hasil Penelitian, 2024)

Gambar 3. Proses Labeling Dataset

Pada Gambar 3 dapat dilihat proses *labeling* menggunakan format YOLO *annotation* untuk memberikan informasi *bounding box* pada setiap gambar. Proses ini juga membedakan dataset menjadi 3 kelas yaitu Britama Black, Britama Silver dan Simpedes.



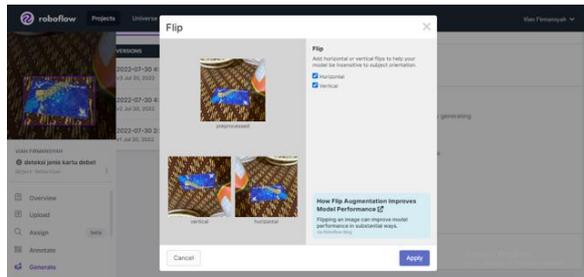
Sumber: (Hasil Penelitian, 2024)

Gambar 4. Proses Resize Dataset

Pada Gambar 4 dapat dilihat proses *resize dataset*. Semua gambar diubah ukurannya menjadi 640x640 sesuai standar *input* YOLOv5.

Augmentasi Dataset

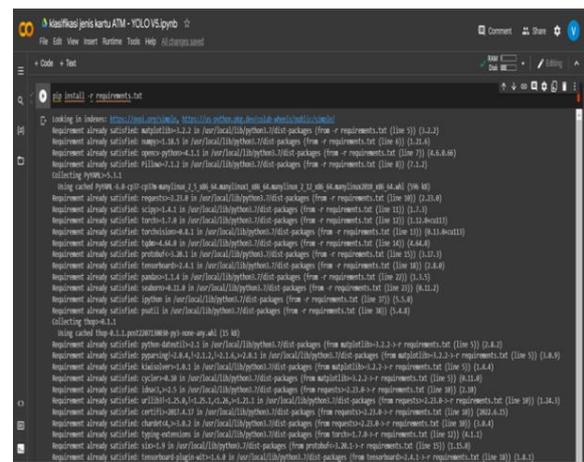
Pada Gambar 5 dapat dilihat proses augmentasi untuk *dataset*. Proses augmentasi yang dilakukan adalah *Flip*. Proses ini membalik gambar dari *dataset* asli secara horizontal dan vertikal. Hal ini dilakukan untuk meningkatkan jumlah gambar pada *dataset*.



Sumber: (Hasil Penelitian, 2024)
Gambar 5. Proses Augmentasi *Dataset*

Modelling YOLOv5

Pada Gambar 5 dapat dilihat proses *modelling* yang telah dilakukan. Penelitian ini menggunakan arsitektur YOLOv5, yaitu versi yang lebih ringan dari keluarga YOLOv5, yang cocok untuk penggunaan di lingkungan dengan keterbatasan sumber daya komputasi. Model dilatih menggunakan GPU standar dari Google Colab, yaitu NVIDIA Tesla K80, yang menyediakan kapasitas pemrosesan yang memadai untuk kebutuhan pelatihan. Proses terdapat 2 sub-proses dalam proses *modelling* yaitu:

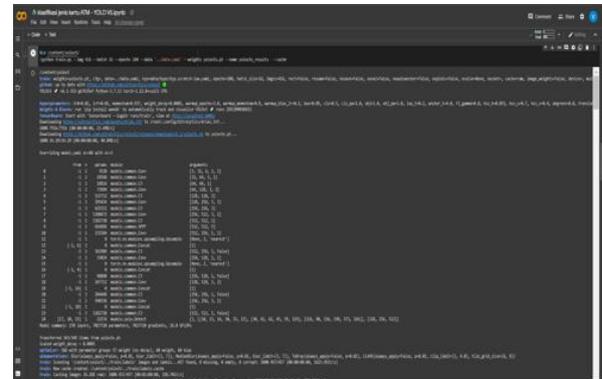


Sumber: (Hasil Penelitian, 2024)
Gambar 5. Proses *Modelling* Menggunakan YOLOv5

Proses Pelatihan Model

Pada Gambar 6 ditampilkan model YOLOv5 dilatih dengan menggunakan *hyperparameter batch size* adalah 16, *epoch* adalah 100, *learning rate*: 0.01, dan *optimizer* Adam. Proses pelatihan dilakukan dengan memantau metrik *mean Average Precision*

(mAP) dan *loss function* untuk mengukur performa model pada *dataset validation*.



Sumber: (Hasil Penelitian, 2024)
Gambar 6. Proses Pelatihan Model

Proses Pengujian Model

Pada Gambar 7 ditampilkan hasil dari pengujian model. Dari hasil tersebut didapat bahwa model dapat mendeteksi objek berupa kartu kredit. Tidak hanya itu, model juga dapat membedakan objek menjadi 3 kelas yaitu Kartu Britama Black, Silver dan Simpedes. Masing-masing objek berhasil dikenali model dengan *confidence* sekitar 95%.



Sumber: (Hasil Penelitian, 2024)
Gambar 7. Hasil Pengujian Model

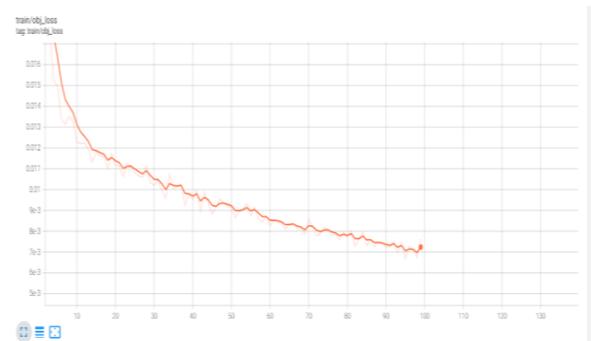
Evaluasi Model

Gambar 8 menampilkan grafik *mean average precision* (mAP) dengan *threshold* sebesar 0,5. Grafik menunjukkan bahwa mAP mulai naik pada *epoch* ke 15. Hasil evaluasi menunjukkan *Mean Average Precision* (mAP) yang tinggi sebesar 92,7%.

Hal ini berarti model dapat mendeteksi objek dengan akurat.



Sumber: (Hasil Penelitian, 2024)
 Gambar 8. Evaluasi Menggunakan mAP



Sumber: (Hasil Penelitian, 2024)
 Gambar 9. Evaluasi Menggunakan Object Loss

Gambar 9 menampilkan grafik *object loss* yang landai. *Object loss* adalah seberapa banyak *bounding box* meleset mendeteksi objek dalam gambar pada proses training. Pada Gambar 9 menunjukkan bahwa semakin banyak *epoch* pada *training*, maka semakin kecil pula *object loss* yang dialami oleh model *training* yang digunakan. Model yang dihasilkan dalam penelitian ini memiliki nilai *Object Loss* yang rendah sebesar 0,08, hal ini menunjukkan bahwa model mengalami sedikit *object loss* pada akhir proses *training* yang berarti model sedikit dalam melakukan kesalahan deteksi.

Hasil penelitian menunjukkan bahwa model YOLOv5 yang dikembangkan berhasil mencapai nilai mAP sebesar 92,7% dengan *Object Loss* yang relatif rendah, yaitu 0,08. Hasil ini menunjukkan keunggulan model dalam mendeteksi dan mengklasifikasikan objek kartu debit secara akurat. Jika dibandingkan dengan penelitian serupa yang menggunakan YOLOv3, nilai mAP penelitian ini lebih tinggi, mengingat YOLOv3 sering memerlukan proses pra dan pasca pemrosesan untuk mencapai tingkat akurasi yang setara. Faktor utama yang mendukung capaian mAP yang tinggi adalah penggunaan augmentasi data, seperti flipping dan rotasi, yang membantu model untuk

lebih *robust* terhadap variasi orientasi kartu. Selain itu, resolusi gambar yang disesuaikan menjadi 640 x 640 piksel memberikan keseimbangan antara akurasi deteksi dan efisiensi komputasi.

Object Loss yang rendah dipengaruhi oleh beberapa faktor, seperti kualitas *dataset* yang memadai, pelabelan yang konsisten, dan pemilihan *hyperparameter* yang tepat, termasuk ukuran *batch* dan jumlah *epoch* yang optimal. Penurunan *Object Loss* pada model ini mencerminkan keberhasilan model dalam meminimalkan kesalahan *bounding box* selama proses pelatihan. Namun, faktor lain seperti kondisi pencahayaan dalam gambar dan keterbatasan variasi *dataset* tetap menjadi tantangan yang dapat memengaruhi performa model secara keseluruhan. Perbandingan ini menunjukkan bahwa YOLOv5 memberikan hasil yang lebih unggul dibandingkan metode sebelumnya, dengan adaptabilitas yang baik terhadap tugas deteksi objek tanpa memerlukan pemrosesan tambahan yang kompleks. Hal ini menunjukkan potensi besar YOLOv5 dalam aplikasi praktis yang membutuhkan deteksi objek yang akurat dan efisien.

KESIMPULAN

Penelitian ini berhasil membangun model deteksi objek menggunakan YOLOv5 pada *dataset* kartu debit dengan hasil evaluasi yang menunjukkan mAP sebesar 92,4% dan *Object Loss* sebesar 0,08. Model ini mampu mendeteksi objek secara akurat pada gambar dengan resolusi yang telah disesuaikan, membuktikan efektivitas pendekatan ini untuk tugas deteksi objek serupa. Namun, terdapat keterbatasan pada jumlah dataset dan variasi kondisi pencahayaan, yang dapat memengaruhi performa model jika diaplikasikan pada lingkungan yang berbeda. Oleh karena itu, disarankan untuk memperluas *dataset* dengan variasi kondisi pencahayaan dan latar belakang yang lebih beragam, serta mengeksplorasi arsitektur model lain atau teknik optimasi *hyperparameter* untuk meningkatkan akurasi dan efisiensi model. Penelitian ini memberikan kontribusi dalam pengembangan teknologi deteksi objek berbasis *deep learning* yang relevan untuk implementasi di berbagai sektor, termasuk industri keuangan dan keamanan.

REFERENSI

Arby, F. H., Husni, I., & Amin, A. (2022). Implementation of YOLO-v5 for a real-time Social Distancing Detection. *Journal of Applied Informatics and Computing*. 6(1), 1-6. <https://doi.org/10.30871/jaic.v6i1.3484>

- Chen, Y. W., & Shiu, J. M. (2022). An implementation of YOLO-family algorithms in classifying the product quality for the acrylonitrile butadiene styrene metallization. *International Journal of Advanced Manufacturing Technology*. <https://doi.org/10.1007/s00170-022-08676-5>
- Chethan Kumar, B., Punitha, R., & Mohana. (2020). YOLOv3 and YOLOv4: Multiple object detection for surveillance applications. *Proceedings of the 3rd International Conference on Smart Systems and Inventive Technology, ICSSIT 2020, IcSSIT*, 1316–1321. <https://doi.org/10.1109/ICSSIT48917.2020.9214094>
- Departemen Penelitian dan Pengaturan Perbankan Otoritas Jasa keuangan. (2021). *Cetak Biru Transformasi Digital Perbankan*. [https://www.ojk.go.id/id/berita-dan-kegiatan/info-terkini/Documents/Pages/Cetak-Biru-Transformasi-Digital-Perbankan/CETAK%20BIRU%20TRANSFORMASI%20DIGITAL%20PERBANKAN%20\(SHORT%20VERSION\).pdf](https://www.ojk.go.id/id/berita-dan-kegiatan/info-terkini/Documents/Pages/Cetak-Biru-Transformasi-Digital-Perbankan/CETAK%20BIRU%20TRANSFORMASI%20DIGITAL%20PERBANKAN%20(SHORT%20VERSION).pdf)
- Helfasari, N. A., Gamayuni, R. R., & Syaipudin, U. (2021). Cashless Banking and Financial Performance of Bank Rakyat Indonesia. *ICEBE 2020: Proceedings of the First International Conference of Economics, Business & Entrepreneurship, ICEBE 2020, 1st October 2020, Tangerang, Indonesia*, 22.
- Hesananda, R., & Agustian, E. Y. (2024). *Generasi Z dan Data Mining: Panduan Klasifikasi Pinjaman Bank sebagai Data Analisis Keuangan*. Penerbit NEM. <https://books.google.co.id/books?id=t-3tEAAAQBAJ>
- Hesananda, R., Noviani, I. A., & Zulfariansyah, M. (2024). Implementasi YOLOv5 untuk Deteksi Objek Mesin EDC: Evaluasi dan Analisis. *BIOS: Jurnal Teknologi Informasi Dan Rekayasa Komputer*, 5(2), 104–110. <https://doi.org/10.37148/bios.v5i2.127>
- Iman, N., Nugroho, S. S., Junarsin, E., & Pelawi, R. Y. (2023). Is technology truly improving the customer experience? Analysing the intention to use open banking in Indonesia. *International Journal of Bank Marketing*, 41(7), 1521–1549. 10.1108/ijbm-09-2022-0427
- Iyer, R., Ringe, P. S., & Bhensdadiya, K. P. (2021). Comparison of YOLOv3, YOLOv5s and MobileNet-SSD V2 for real-time mask detection. *Artic. Int. J. Res. Eng. Technol*, 8, 1156–1160.
- Jikrillah, S., & Fadah, I. (2023). Financial Performance of Indonesia Banking: The Impact of Digital Banking. *ICIFEB 2022: Proceedings of the 3rd International Conference of Islamic Finance and Business, ICIFEB 2022, 19-20 July 2022, Jakarta, Indonesia*, 281.
- Kivrak, O., & Gürbüz, M. Z. (2022). Performance comparison of yolov3, yolov4 and yolov5 algorithms: A case study for poultry recognition. *Avrupa Bilim ve Teknoloji Dergisi*, 38, 392–397.
- Kuznetsova, A., Maleva, T., & Soloviev, V. (2021). YOLOv5 versus YOLOv3 for apple detection. In *Cyber-Physical Systems: Modelling and Intelligent Control* (pp. 349–358). Springer.
- Mulyana, R., Rusu, L., & Perjons, E. (2023). How Hybrid IT Governance Mechanisms Influence Digital Transformation and Organizational Performance in the Banking and Insurance Industry in Indonesia. *The International Conference on Information Systems Development (ISD)*, 1–12.
- Nepal, U., & Eslamiat, H. (2022). Comparing YOLOv3, YOLOv4 and YOLOv5 for autonomous landing spot detection in faulty UAVs. *Sensors*, 22(2), 464.
- PT Bank Mandiri (Persero) Tbk. (2021). *Melanjutkan Transformasi Digital & Inovasi Perbankan*. https://www.idx.co.id/StaticData/NewsAndAnnouncement/ANNOUNCEMENTSTOCK/From_EREP/202202/ef15dbcba6_0a7f8a125f.pdf
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*. 27(3), 306–308. <https://doi.org/10.1021/je00029a022>
- Sarosa, M., Muna, N., Elektro, J. T., Malang, P. N., Korespondensi, P., Korban, D., Objek, D., & Only, Y. (2021). *Implementasi Algoritma You Only Look Once (Yolo) Untuk Implementation of You Only Look Once (Yolo) Algorithm for*. 8(4), 787–792. <https://doi.org/10.25126/jtiik.202184407>
- Tristanto, T. A., Nugraha, N., Waspada, I., Mayasari, M., & Kurniati, P. S. (2023). Sustainability performance impact of corporate performance in Indonesia banking. *Journal of Eastern European and Central Asian Research (JEECAR)*, 10(4), 668–678. <https://doi.org/10.15549/jeeocar.v10i4.1364>
- Wardhani, D., & Wijaya, A. P. (2020). User Interface Prototype Design Of Mobile Application Academic Information Systems Institute Of Technology And Business Of Indonesian

Banks. *BRITech (Jurnal Ilmiah Komputer, Sains Dan Teknologi Terapan)*, 1(2), 25-31.

Yusro, M. M., Ali, R., & Hitam, M. S. (2023). Comparison of faster r-cnn and yolov5 for overlapping objects recognition. *Baghdad Science Journal*, 20(3), 893. <https://doi.org/10.21123/bsj.2022.7243>