

PENGEMBANGAN MODEL KLASIFIKASI NOMINAL UANG KERTAS RUPIAH BERBASIS TRANSFER LEARNING UNTUK TUNANETRA

M.Farhan Rizkilillah¹⁾, Salman Alfarissi²⁾, Marwan Muharram³⁾, dan Muhammad Zaki Basyir Ashidiq⁴⁾

^{1, 2, 3, 4)} Teknik Informatika, Fakultas Teknik Komputer dan Desain, Universitas Nusa Putra

Jl. Raya Cibolang No.21, Cibolang Kaler, Kec.Cisaat, Kabupaten Sukabumi, Jawa Barat 43152

e-mail: m.farhan_ti23@nusaputra.ac.id¹⁾, salman.alfarissi_ti23@nusaputra.ac.id²⁾,
marwan.muhammad_ti23@nusaputra.ac.id³⁾, muhammad.zaki_ti23@nusaputra.ac.id⁴⁾

* Korespondensi: muhammad.zaki_ti23@nusaputra.ac.id

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan sistem pengenalan nominal uang kertas Rupiah berbasis deep learning menggunakan arsitektur YOLO (You Only Look Once) guna membantu penyandang tunanetra dalam mengenali nilai nominal uang secara mandiri dan real-time. Berbeda dengan metode klasifikasi standar, YOLO memungkinkan deteksi objek sekaligus klasifikasi dalam satu tahapan proses, sehingga lebih responsif untuk penggunaan pada perangkat bergerak. Dataset yang digunakan terdiri dari citra uang kertas Rupiah dengan tujuh kelas nominal, yaitu Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000, yang diperoleh melalui pengambilan gambar secara langsung menggunakan kamera. Dataset dibagi ke dalam data pelatihan, validasi, dan pengujian. Model dilatih menggunakan algoritma YOLO dengan optimasi pada bounding box dan prediksi kelas nominal. Hasil pelatihan menunjukkan bahwa implementasi YOLO mampu memberikan tingkat akurasi yang tinggi serta kecepatan pemrosesan (FPS) yang stabil, yang sangat krusial untuk membantu penderita gangguan penglihatan dalam melakukan transaksi sehari-hari secara akurat.

Kata Kunci: Uang Rupiah, Tunanetra, Deteksi Objek, YOLO, Deep Learning.

ABSTRACT

This study aims to develop a Rupiah banknote denomination recognition system based on deep learning using the YOLO (You Only Look Once) architecture to assist visually impaired individuals in recognizing banknote values independently and in real-time. Unlike standard classification methods, YOLO enables simultaneous object detection and classification in a single process stage, making it more responsive for use on mobile devices. The dataset consists of Rupiah banknote images with seven denomination classes: IDR 1,000, IDR 2,000, IDR 5,000, IDR 10,000, IDR 20,000, IDR 50,000, and IDR 100,000, obtained through direct image capture using a camera. The dataset is divided into training, validation, and testing data. The model is trained using the YOLO algorithm with optimization on bounding boxes and nominal class predictions. The training results demonstrate that the YOLO implementation provides high accuracy and stable processing speed (FPS), which is crucial for helping people with visual impairments perform daily transactions accurately.

Keywords: Rupiah Banknotes, Visually Impaired, Object Detection, YOLO, Deep Learning.

I. PENDAHULUAN

Dalam upaya mengatasi hambatan aksesibilitas bagi penyandang tunanetra, teknologi pengenalan citra digital menjadi solusi yang sangat potensial. Salah satu pendekatan mutakhir dalam visi komputer adalah menggunakan metode YOLO (You Only Look Once)[1]. Pemilihan YOLO didasarkan pada kemampuannya untuk melakukan deteksi objek secara real-time dengan akurasi yang kompetitif. Berbeda dengan arsitektur klasifikasi gambar tradisional yang memproses gambar dalam beberapa tahap, YOLO melihat seluruh gambar dalam satu kali proses iterasi (single shot detector), sehingga mampu menentukan lokasi (bounding box) dan klasifikasi nominal uang secara bersamaan[2].

Kelebihan utama YOLO terletak pada kecepatannya yang luar biasa tanpa mengorbankan performa deteksi, yang sangat dibutuhkan oleh penyandang tunanetra saat menggunakan kamera ponsel di lingkungan yang dinamis[3]. Penelitian ini memanfaatkan dataset lokal yang mencakup tujuh pecahan nominal uang kertas Rupiah untuk melatih model YOLO agar mampu mengenali ciri khas visual setiap pecahan uang, bahkan dalam kondisi pencahayaan atau sudut pandang yang bervariasi[4]. Dengan implementasi metode

ini, diharapkan sistem dapat memberikan respons yang cepat dan akurat sebagai teknologi bantu (assistive technology) yang praktis digunakan sehari-hari[5].

II. Kajian Teori

A. *Algoritma YOLO (You Only Look Once)*

YOLO (You Only Look Once) merupakan terobosan dalam deep learning yang mengintegrasikan seluruh tahapan deteksi objek ke dalam satu jaringan saraf tunggal[6]. Berbeda dengan metode berbasis region proposal seperti R-CNN yang memproses gambar secara bertahap, YOLO memperlakukan deteksi sebagai masalah regresi tunggal yang memprediksi koordinat spasial dan probabilitas kelas secara bersamaan[7]. Keunggulan utama dari algoritma ini adalah kemampuannya dalam melakukan deteksi secara real-time dengan latency yang sangat rendah, sehingga sangat responsif terhadap perubahan lingkungan visual[8].

Secara operasional, YOLO membagi citra menjadi sistem grid di mana setiap sel bertanggung jawab untuk memprediksi sejumlah bounding box[1]. Setiap kotak tersebut membawa informasi berupa skor kepercayaan (confidence score) yang mencerminkan keakuratan model dalam mendeteksi objek[7]. Pada perkembangannya, berbagai varian seperti YOLOv5 hingga YOLOv8 telah dioptimalkan untuk berjalan pada perangkat dengan keterbatasan komputasi tanpa mengurangi nilai presisi secara signifikan[9].

B. *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) adalah fondasi utama yang memungkinkan mesin mempelajari representasi data citra secara hierarkis[8]. Melalui lapisan konvolusi, CNN mampu mengekstraksi fitur visual mulai dari yang sederhana seperti garis dan tepi, hingga fitur kompleks seperti pola tekstur pada uang kertas[10]. Proses ini didukung oleh mekanisme weight sharing yang secara drastis mengurangi jumlah parameter yang perlu dilatih dibandingkan dengan jaringan saraf tradisional[11].

Dalam arsitektur CNN modern, penggunaan pooling layer sangat krusial untuk melakukan downsampling fitur guna meningkatkan invariansi model terhadap pergeseran posisi objek[11]. Selain itu, integrasi fungsi aktivasi non-linear dan teknik normalisasi membantu mempercepat konvergensi selama proses pelatihan model[6]. Kemampuan ekstraksi otomatis ini membuat CNN jauh lebih unggul daripada teknik visi komputer konvensional dalam mengenali objek yang bervariasi[12].

C. *Deep Learning untuk Deteksi Objek dan Transfer Learning*

Penerapan deep learning dalam deteksi objek memungkinkan identifikasi lokasi dan kategori objek secara simultan dalam satu frame citra[9]. Salah satu teknik yang paling efisien untuk melatih model ini adalah Transfer Learning, di mana pengetahuan dari model pre-trained pada dataset skala besar seperti ImageNet digunakan kembali untuk tugas yang lebih spesifik[11]. Teknik ini memungkinkan pengembangan model yang akurat meskipun hanya memiliki jumlah dataset yang terbatas, seperti pada kasus koleksi citra uang Rupiah lokal[4].

Untuk mengukur keberhasilan model deteksi, parameter evaluasi seperti Mean Average Precision (mAP) dan kecepatan bingkai per detik (Frame Per Second/FPS) menjadi indikator utama[13]. Penggunaan deep learning memastikan bahwa sistem deteksi memiliki ketahanan (robustness) terhadap gangguan visual seperti pencahayaan yang minim, kemiringan sudut pandang, hingga kondisi uang yang lusuh atau terlipat[12].


D. *Teknologi Bantu (Assistive Technology) bagi Tunanetra*

Teknologi bantu (assistive technology) merupakan inovasi yang dirancang untuk menjembatani kesenjangan aksesibilitas serta meningkatkan kualitas hidup penyandang disabilitas dalam melakukan aktivitas sehari-hari[5]. Dalam konteks pengenalan mata uang Rupiah, teknologi berbasis visi komputer hadir sebagai solusi praktis bagi penyandang tunanetra yang sering kali menghadapi hambatan saat menggunakan fitur blind code (kode tuna netra) konvensional[3]. Masalah utama di lapangan menunjukkan bahwa fitur blind code pada uang kertas sering kali sulit diidentifikasi apabila kondisi uang sudah lama, lusuh, atau mengalami kerusakan fisik[12].

Pengembangan sistem ini mengintegrasikan algoritma deteksi objek mutakhir dengan mekanisme output suara untuk memberikan umpan balik secara instan (real-time)[4]. Dengan memanfaatkan kamera perangkat bergerak, sistem dapat mengenali nominal uang dan mengonversinya menjadi informasi suara yang mudah dipahami[8]. Implementasi teknologi ini tidak hanya sekedar membantu pengenalan angka, tetapi lebih jauh lagi bertujuan untuk mendukung kemandirian finansial dan keamanan penyandang tunanetra dalam melakukan transaksi ekonomi secara mandiri tanpa harus bergantung pada bantuan orang lain[10]

III. METODE

Tahapan metode yang dilakukan dalam penelitian deteksi dan klasifikasi uang rupiah ini dijelaskan pada gambar I berikut:



Gambar I. Diagram Alur Sistem
Sumber: Hasil Penelitian (2026)

A. Pengumpulan Dataset

Pada tahapan ini, dilakukan pengumpulan data citra uang kertas Rupiah yang terdiri dari tujuh nominal uang yang diambil dari platform Roboflow. Pengumpulan data mencakup karakteristik visual uang kertas meliputi warna, desain tokoh pahlawan, dan angka nominal dalam berbagai kondisi pencahayaan serta sudut pandang. Total dataset yang digunakan adalah 1.400 gambar yang dibagi secara merata ke dalam tujuh kelas nominal. Berikut adalah tabel rincian pembagian data untuk masing-masing kelas:

Tabel I. Jumlah Dataset
Sumber: Hasil Penelitian (2026)

Kelas Nominal	Data Latih (Train)	Data Validasi (Val)	Data Tes (Test)	Total per Kelas	Kelas Nominal	Data Latih (Train)
---------------	--------------------	---------------------	-----------------	-----------------	---------------	--------------------

Rp 1.000	114	43	43	200	Rp 1.000	114
Rp 2.000	114	43	43	200	Rp 2.000	114
Rp 5.000	114	43	43	200	Rp 5.000	114
Rp 10.000	114	43	43	200	Rp 10.000	114
Rp 20.000	114	43	43	200	Rp 20.000	114
Rp 50.000	115	42	43	200	Rp 50.000	115
Rp 100.000	115	43	42	200	Rp 100.000	115
TOTAL	800	300	300	1.400	TOTAL	800

B. Preprocessing

Pembersihan Data: Tahapan awal dalam pengolahan dataset bertujuan untuk menyiapkan data citra sebelum digunakan pada proses pelatihan model. Pada tahap ini dilakukan pembersihan data mentah yang telah diperoleh dari Roboflow, seperti menghapus data yang tidak lengkap, tidak relevan, atau terduplikasi, sehingga kualitas dataset menjadi lebih optimal. Tahapan ini penting untuk meminimalkan kesalahan (noise) dan meningkatkan performa model dalam melakukan klasifikasi nominal uang.

Resizing (Ukuran Citra): Selanjutnya, dilakukan proses resizing pada seluruh citra dengan mengubah ukuran citra menjadi 640×640 piksel. Penyeragaman ukuran ini bertujuan agar seluruh data memiliki dimensi yang konsisten saat diproses oleh arsitektur YOLOv8. Pemilihan resolusi 640×640 piksel disesuaikan dengan parameter `imgsz=640` pada kode pelatihan, yang memungkinkan model menangkap detail fitur penting seperti angka nominal dan tekstur pahlawan pada uang kertas secara lebih tajam dibandingkan resolusi standar yang lebih rendah.

Normalisasi dan Labeling: Dataset yang telah dibersihkan kemudian dipastikan memiliki format label yang sesuai dengan standar YOLO (format .txt dengan koordinat bounding box). Hal ini memastikan model dapat mempelajari posisi (localization) sekaligus kategori (classification) dari tujuh nominal uang Rupiah secara bersamaan.

C. Pelatihan Model

Pelatihan atau training model merupakan tahapan krusial di mana arsitektur model dikembangkan agar memiliki kemampuan generalisasi yang baik saat dilakukan pengujian. Dalam penelitian ini, proses pelatihan dilakukan menggunakan arsitektur YOLOv8 (You Only Look Once versi 8) yang dilatih secara berulang melalui mekanisme pemberian data, evaluasi kinerja pada setiap tahapan, dan penyesuaian parameter untuk menghasilkan prediksi klasifikasi nominal uang yang akurat. Proses ini melibatkan penggunaan berbagai parameter teknis seperti jumlah epoch, ukuran citra input, serta metode optimasi. Berbeda dengan arsitektur klasifikasi standar, YOLOv8 memanfaatkan struktur backbone dan head yang dioptimasi untuk deteksi objek secara real-time di perangkat mobile.

Pada penelitian ini, pelatihan model dilakukan sebanyak 100 epoch dengan menggunakan ukuran citra input 640×640 piksel. Untuk menangani masalah kemiripan visual pada nominal tertentu seperti Rp 2.000 dan Rp 20.000, diterapkan strategi augmentasi data terintegrasi yang mencakup penyesuaian Hue, Saturation, Value (HSV) serta teknik Mosaic dan Mixup. Teknik Mosaic menggabungkan empat gambar pelatihan menjadi satu untuk membantu model mengenali objek dalam berbagai konteks lokasi, sementara Mixup membantu model membedakan fitur-fitur halus pada kelas yang memiliki kemiripan warna. Metode optimasi yang digunakan adalah Stochastic Gradient Descent (SGD) dengan initial learning rate sebesar 0.01 guna memastikan konvergensi akurasi yang stabil. Parameter spesifik yang digunakan dalam proses pelatihan ini dirangkum dalam tabel berikut.

Tabel II. Parameter Pelatihan YOLOv8

Sumber: Hasil Penelitian (2026)

No	Nama Parameter	Nilai (Size/Value)
1	Arsitektur Model	yolov8n.pt
2	Iterasi Pelatihan	100

3	Ukuran Citra Input	640 x 640
4	Metode Optimasi	SGD
5	Laju Pembelajaran	0.01
6	Augmentasi Mosaic	1.0
7	Augmentasi Mixup	0.2
8	Variasi Corak (Hue)	0.015
9	Variasi Saturasi	0.7

Model melakukan proses pembelajaran melalui iterasi forward propagation dan backward propagation selama 100 epoch yang telah ditentukan atau hingga kondisi early stopping terpenuhi. Pada tahap forward propagation, data citra uang kertas Rupiah diproses melalui lapisan backbone dan neck untuk ekstraksi fitur, serta lapisan head untuk menghasilkan prediksi koordinat bounding box dan kelas nominal. Selanjutnya, pada backward propagation, kesalahan prediksi dihitung menggunakan fungsi loss yang mencakup *box loss*, *classification loss*, dan *distribution focal loss* (DFL), yang kemudian digunakan untuk memperbarui bobot jaringan.

Pembaruan bobot dilakukan setiap kali satu *batch* data diproses dengan menggunakan metode Stochastic Gradient Descent (SGD). Dalam penelitian ini, penggunaan optimizer SGD bertujuan untuk menjaga stabilitas pembaruan gradien selama proses pelatihan, sehingga model dapat mencapai konvergensi yang lebih optimal dalam mengenali pola tekstur dan warna pada tujuh kelas nominal uang kertas Rupiah. Penggunaan SGD juga membantu model dalam melakukan generalisasi yang lebih baik pada data baru dibandingkan beberapa metode adaptif lainnya pada arsitektur YOLOv8 Nano.

D. Pengujian Model

Tahap pengujian dilakukan menggunakan 300 data uji yang telah dipisahkan dari dataset awal untuk mengevaluasi kemampuan generalisasi model. Pada tahap ini, model YOLOv8 diuji untuk mendeteksi tujuh nominal uang kertas Rupiah (Rp1.000 hingga Rp100.000) pada berbagai kondisi citra yang belum pernah dipelajari sebelumnya.

Proses pengujian berfokus pada dua aspek utama: klasifikasi objek untuk menentukan nominal uang dan lokalisasi untuk menentukan posisi objek melalui *bounding box*. Evaluasi dilakukan dengan membandingkan hasil prediksi model terhadap *ground truth* menggunakan metrik Mean Average Precision (mAP), Precision, dan Recall. Tahap ini bertujuan untuk memastikan model memiliki tingkat keandalan yang tinggi sebelum masuk ke tahap implementasi pada aplikasi.

E. Evaluasi Model

Evaluasi model merupakan tahap penting untuk menilai kinerja model CNN yang telah dilatih. Evaluasi dilakukan guna menentukan seberapa baik model mampu melakukan klasifikasi nominal uang kertas Rupiah secara tepat. Dalam penelitian ini, performa model dievaluasi menggunakan empat metrik utama, yaitu akurasi (*accuracy*), presisi (*precision*), recall, dan F1-score. Pengukuran performa dilakukan berdasarkan confusion matrix, yang menggambarkan perbandingan antara hasil prediksi model dan label sebenarnya. Keempat metrik evaluasi tersebut digunakan untuk memberikan gambaran yang lebih komprehensif mengenai kemampuan model, terutama dalam membedakan antar kelas nominal uang yang memiliki kemiripan visual.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

$$Precision = \frac{TP}{TP+FP}$$

$$Recall = \frac{TP}{TP+FN}$$

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$


Keterangan

- **Accuracy** adalah rasio antara jumlah prediksi yang benar, baik positif maupun negatif, terhadap keseluruhan jumlah prediksi yang dilakukan oleh model.
- **Precision** merupakan rasio antara jumlah prediksi positif yang benar dengan total prediksi positif yang dihasilkan oleh model.
- **Recall** adalah rasio antara jumlah prediksi positif yang benar dengan total jumlah data yang sebenarnya termasuk ke dalam kelas positif.
- **F1-Score** merupakan nilai harmonis yang menggabungkan precision dan recall untuk memberikan gambaran menyeluruh mengenai kinerja model klasifikasi

IV. HASIL DAN PEMBAHASAN

Pelatihan model deteksi nominal uang kertas Rupiah pada penelitian ini menggunakan arsitektur YOLOv8 dengan pendekatan transfer learning. Berbeda dengan metode klasifikasi standar, model ini dioptimasi menggunakan optimizer SGD (Stochastic Gradient Descent) yang terbukti memberikan stabilitas lebih baik dalam konvergensi bobot jaringan untuk tugas deteksi objek. Proses pelatihan dilakukan dengan konfigurasi batch size yang disesuaikan dengan kapasitas memori GPU guna mencapai performa yang optimal.

Jumlah epoch yang ditetapkan dalam penelitian ini adalah 100 epoch. Berdasarkan hasil pemantauan, jumlah tersebut memberikan ruang yang cukup bagi model untuk mencapai kondisi stabil tanpa mengalami overfitting. Perkembangan performa model selama proses pelatihan terekam dalam grafik metrik yang ditunjukkan pada Gambar II.



Gambar II. Hasil Pelatihan Model YOLOv8
Sumber: Hasil Penelitian (2026)

Proses pelatihan model dilakukan sebanyak 100 epoch dengan memantau perkembangan nilai loss dan metrik akurasi secara berkala. Berdasarkan grafik pada Gambar 4.1, terlihat tren penurunan nilai loss (box, cls, dan dfl loss) yang konsisten baik pada data latih maupun validasi, yang mengindikasikan model berhasil meminimalkan kesalahan deteksi tanpa mengalami overfitting.

Sejalan dengan itu, metrik mAP50 menunjukkan peningkatan pesat dan mencapai stabilitas di atas 0.95 setelah melewati epoch ke-50, dengan hasil akhir mendekati 0.965. Stabilitas pada grafik precision dan recall yang berada di ambang batas maksimal membuktikan bahwa model memiliki keandalan yang sangat tinggi dalam mengklasifikasikan tujuh nominal uang Rupiah secara presisi. Hasil pelatihan ini selanjutnya diuji menggunakan data uji untuk mendapatkan prediksi, yang direpresentasikan dalam bentuk matriks seperti pada Tabel III.

Tabel III. Hasil Prediksi Nominal Uang Kertas Rupiah
Sumber: Hasil Penelitian (2026)


CLASS ACTUAL	RP 1.000	RP 10.000	RP 100.000	RP 2.000	RP 20.000	RP 5.000	RP 50.000	BACKGROUND
RP 1.000	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
RP 10.000	0.00	0.96	0.00	0.00	0.00	0.00	0.00	0.04
RP 100.000	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
RP 2.000	0.00	0.00	0.00	0.74	0.00	0.00	0.00	0.26
RP 20.000	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.00
RP 5.000	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00
RP 50.000	0.00	0.00	0.00	0.00	0.00	0.00	0.97	0.03

Performa model YOLOv8 yang telah melalui tahap pengujian kemudian dievaluasi menggunakan metrik akurasi berdasarkan perhitungan Precision, Recall, dan F1-Score. Hasil evaluasi ini digunakan untuk mengukur kualitas deteksi dan klasifikasi yang dihasilkan oleh model terhadap nominal uang kertas Rupiah. Detail mengenai performa klasifikasi model YOLOv8 untuk setiap kelas nominal disajikan secara mendalam pada Tabel IV.

Tabel IV. Hasil Prediksi Nominal Uang Kertas Rupiah
Sumber: Hasil Penelitian (2026)

CLASS	PRECISION	RECALL	F1-SCORE
RP 1.000	1.00	1.00	1.00
RP 10.000	1.00	0.96	0.98
RP 100.000	1.00	1.00	1.00
RP 2.000	1.00	0.74	0.85
RP 20.000	1.00	1.00	1.00
RP 5.000	1.00	1.00	1.00
RP 50.000	1.00	0.97	0.98
MAP50 (MEAN ACCURACY)			0.965

Model mencapai nilai mAP50 sebesar 0.965, yang menunjukkan tingkat keandalan sistem sangat tinggi dalam mendeteksi berbagai nominal uang Rupiah. Nilai Precision sempurna (1.00) di seluruh kelas mengonfirmasi bahwa tidak ada kesalahan klasifikasi antar nominal. Namun, nilai Recall terendah terdapat pada nominal Rp2.000 (0.74), hal ini disebabkan oleh adanya beberapa data uji yang tidak terdeteksi oleh model atau dianggap sebagai background.



Gambar III. Hasil Prediksi Nominal Uang Kertas Rupiah
Sumber: Hasil Penelitian (2026)

Hasil pengujian pada Gambar III menunjukkan kemampuan model dalam mendeteksi dan mengklasifikasikan nominal uang menggunakan dataset dengan skor kepercayaan (*confidence score*) yang tinggi, mayoritas di atas 0.9. Sistem berhasil melokalisasi posisi uang kertas menggunakan *bounding box* dan menampilkan label nominal secara akurat pada berbagai kondisi objek, termasuk uang yang terlipat. Selain tampilan visual, sistem ini mengintegrasikan keluaran suara (*audio output*) untuk menyebutkan nominal yang terdeteksi, guna membantu aksesibilitas bagi penyandang tuna netra. Meskipun secara umum akurat, hasil inferensi mengonfirmasi adanya tantangan pada nominal Rp2.000 yang terkadang memiliki skor kepercayaan lebih rendah atau mengalami salah prediksi saat kondisi visual tidak optimal.

V. KESIMPULAN

Berdasarkan hasil penelitian dan pengujian yang telah dilakukan, dapat disimpulkan bahwa arsitektur YOLOv8 mampu mendeteksi dan mengklasifikasikan nominal uang kertas Rupiah dengan performa yang sangat baik. Model yang dilatih selama 100 epoch ini mencapai tingkat akurasi mAP50 sebesar 0.965, yang menunjukkan tingkat presisi dan keandalan tinggi dalam mengenali fitur visual setiap nominal.

Evaluasi melalui confusion matrix dan metrik performa menunjukkan nilai Precision sempurna (1.00) pada seluruh kelas, meskipun terdapat tantangan pada nominal Rp2.000 dengan nilai recall sebesar 0.74 akibat kendala deteksi pada kondisi visual tertentu. Sistem yang dikembangkan juga telah berhasil mengintegrasikan fitur keluaran suara (*audio output*), sehingga fungsional sebagai teknologi bantu (*assistive technology*) yang memudahkan penyandang tuna netra mengenali nilai uang secara mandiri. Secara keseluruhan, YOLOv8 terbukti menjadi arsitektur yang efektif dan efisien untuk sistem deteksi uang Rupiah berbasis citra.

VI. DAFTAR PUSTAKA

- [1] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," 2016. [Online]. Available: <http://pjreddie.com/yolo/>
- [2] R. D. Saputra, "Pengembangan sistem deteksi objek pada produk retail dengan arsitektur YOLOv4-tiny," Universitas Islam Indonesia, Yogyakarta, 2023. Accessed: Dec. 15, 2026. [Online]. Available: <https://dspace.uui.ac.id/handle/123456789/45878>
- [3] A. Prima, D. B. Santoso, and L. Nulpulaela, "Deteksi otomatis nominal uang kertas rupiah untuk tunanetra menggunakan algoritma arsitektur SSD MobileNetv3," *TEKNOKOM*, vol. 6, no. 2, pp. 151–159, Aug. 2023, doi: 10.31943/teknokom.v6i2.166.
- [4] M. F. Mahfuzh, M. N. Abdillah, and B. Fatkhurrozi, "Deteksi rupiah emisi 2022 untuk disabilitas netra menggunakan YOLOv5m dengan output suara," *INTI Nusa Mandiri*, vol. 19, no. 1, pp. 01–09, Jun. 2024, doi: 10.33480/inti.v19i1.5295.

- [5] F. Z. R. Widodo, “Rancang bangun aplikasi pendeteksi nominal uang kertas rupiah menggunakan Flutter dengan arsitektur MobileNetV2 untuk tunanetra,” Sarjana thesis, Universitas Islam Negeri Sunan Gunung Djati Bandung., Bandung, 2023. Accessed: Dec. 15, 2025. [Online]. Available: <https://digilib.uinsgd.ac.id/id/eprint/83002>.
- [6] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, “YOLOv4: Optimal speed and accuracy of object detection,” pp. 1–17, Apr. 2020, Accessed: Dec. 15, 2026. [Online]. Available: <http://arxiv.org/abs/2004.10934>
- [7] J. Redmon and A. Farhadi, “YOLOv3: An incremental improvement,” pp. 1–6, Apr. 2018, Accessed: Dec. 15, 2026. [Online]. Available: <http://arxiv.org/abs/1804.02767>
- [8] A. M. N. Hidayat, Antamil, and I. M. Zakiyah, “Identifikasi nominal mata uang rupiah bagi penyandang tunanetra dengan algoritma convolutional neural network berbasis android,” pp. 60–65, Jun. 2023, doi: <https://doi.org/10.24252/shift.v3i2.102>.
- [9] C. Charleen and G. P. Kusuma, “Evaluation of deep learning models for detection of Indonesian rupiah,” *International Journal of Computing and Digital Systems*, vol. 16, no. 1, pp. 315–327, Jul. 2024, doi: [10.12785/ijcds/160125](https://doi.org/10.12785/ijcds/160125).
- [10] M. Z. Hanif, W. A. Saputra, Y. H. Choo, and A. P. Yunus, “Rupiah banknotes detection comparison of the Faster R-CNN algorithm and YOLOv5,” Aug. 2024. doi: <https://doi.org/10.20895/infotel.v16i3.1189>.
- [11] A. G. Howard *et al.*, “MobileNets: Efficient convolutional neural networks for mobile vision applications,” pp. 1–9, Apr. 2017, Accessed: Dec. 15, 2026. [Online]. Available: <http://arxiv.org/abs/1704.04861>
- [12] K. M. Azhar, I. Santoso, and Y. A. A. Soetrisno, “Implementasi deep learning menggunakan metode convolutional neural network dan algoritma YOLO dalam sistem pendeteksi uang kertas rupiah bagi penyandang low vision,” *TRASIENT*, vol. 10, no. 3, pp. 502–509, Sep. 2021, Accessed: Dec. 15, 2025. [Online]. Available: <https://ejournal3.undip.ac.id/index.php/transient>
- [13] N. Fanzury and M. Hwang, “Real-time identification of mixed and partly covered foreign currency using YOLOv11 object detection,” *AI (Switzerland)*, vol. 6, no. 10, pp. 1–21, Oct. 2025, doi: [10.3390/ai6100241](https://doi.org/10.3390/ai6100241).