

DETEKSI RUPIAH EMISI 2022 UNTUK DISABILITAS NETRA MENGUNAKAN YOLOV5M DENGAN OUTPUT SUARA

Muhammad Farhan Mahfuzh¹; Mokhammad Nurkholis Abdillah^{2*}; Bagus Fatkhurrozi³

Program Studi Teknik Elektro^{1,2,3}

Universitas Tidar^{1,2,3}

<https://untidar.ac.id>^{1,2,3}

muhammadfarhanmahfuzh@students.untidar.ac.id¹; mnurkholisabdillah@untidar.ac.id^{2*};

bagusfatkhurozzi@untidar.ac.id³

(*) Corresponding Author



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

Abstract—People with visual disabilities have difficulty recognizing rupiah denominations using blind codes due to differences in paper size for each denomination, wrinkled paper, and variations in blind codes for different emission years. The proposed method uses the YOLOv5m algorithm as well as Google Text to Speech (GTTS) as voice output. The aim of the research is to find a model with the best precision value from YOLOv5m in detecting the 2022 emission rupiah and integrate it into GTTS to produce nominal rupiah sounds. The model was trained with the main image dataset, namely 700 images of rupiah emissions in 2022 taken at an angle of 120°. Next, the model was tested to recognize seven nominal amounts, namely IDR 1,000, IDR 2,000, IDR 5,000, IDR 10,000, IDR 20,000, IDR 50,000, and IDR 100,000. The test results show that the best YOLOv5m model is the one that has been trained using the main dataset (700 images) and supplemented with a multi-class image dataset (250 images) and background images (30 images). This model has a precision value of 82% when testing in real time. This research succeeded in applying the YOLOv5 algorithm which is integrated with Google Text to Speech to detect the image of 2022 emission rupiah banknotes.

Keywords: 120 degree image, 2022 rupiah emission, google text to speech, YOLOv5m.

Abstrak—Penyandang disabilitas netra kesulitan dalam mengenali nominal rupiah menggunakan blind code karena perbedaan ukuran kertas tiap nominal, kertas yang lecek, dan variasi blind code untuk tahun emisi berbeda. Metode yang diusulkan menggunakan algoritma YOLOv5m serta Google Text to Speech (GTTS) sebagai output suara. Tujuan penelitian adalah menemukan model dengan nilai presisi terbaik dari YOLOv5m dalam mendeteksi rupiah emisi 2022 dan mengintegrasikan ke GTTS untuk mengeluarkan suara nominal rupiah. Model dilatih dengan dataset citra utama, yaitu 700 citra rupiah emisi tahun 2022 yang diambil pada sudut 1200. Selanjutnya, model diuji untuk mengenali tujuh nominal, yaitu Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000. Hasil pengujian menunjukkan model YOLOv5m terbaik adalah yang telah dilatih menggunakan dataset utama (700 citra) dan ditambah dengan dataset citra multi class (250 citra) dan citra background (30 citra). Model tersebut memiliki nilai presisi sebesar 82% saat pengujian secara realtime. Penelitian ini berhasil menerapkan algoritma YOLOv5m yang terintegrasi dengan Google Text to Speech untuk mendeteksi citra uang kertas rupiah emisi 2022.

Kata kunci: citra 120 derajat, uang rupiah emisi 2022, google text to speech, YOLOv5m.

PENDAHULUAN

Bank Indonesia pada tahun 2022 memperkenalkan 7 pecahan uang rupiah tahun emisi (TE) 2022 dengan desain baru yang lebih aman digunakan (Rachma, 2022). Perubahan desain terutama pada ukuran yang digunakan, dimana selisih tiap nominal sebesar 5mm. Bagi penyandang

disabilitas netra perubahan ukuran tersebut dapat digunakan untuk mengenali nominal rupiah TE 2022, namun cara tersebut dirasa kurang efektif karena membedakan ukuran sebesar 5mm bagi disabilitas netra bukan perkara mudah. Cara lain untuk mengenali nominal rupiah TE 2022 bagi disabilitas netra adalah melalui fitur *blind code* yang mirip nominal rupiah TE 2016 (Hertanto, 2022).

Namun demikian, mengenali fitur *blind code* membutuhkan ketelitian. Kendala dalam mengenali *blind code*, antara lain perbedaan ukuran kertas (millimeter) berbagai nominal, penggunaan kertas yang mudah lusuh menyebabkan *blind code* kurang tegas saat diraba sehingga salah mengenali, dan variasi *blind code* pada tahun emisi berbeda memiliki karakteristik tersendiri (Hafiar et al., 2020). Berdasarkan kondisi yang demikian para penyandang disabilitas netra membutuhkan alat bantu yang tidak hanya mampu mendeteksi nominal rupiah, tetapi juga mampu mengeluarkan suara nominal hasil deteksi tersebut.

Untuk mengatasi permasalahan diatas beberapa penelitian mengusulkan penerapan sistem berbasis mikrokontroler untuk mendeteksi nominal uang kertas rupiah dengan *output* suara. Alat deteksi nominal rupiah TE 2016 dikembangkan menggunakan ATmega328, sensor RGB TCS230 dan speaker. Alat tersebut berhasil mendeteksi nominal rupiah dan mengeluarkan *output* suara sesuai uang yang dideteksi (Pujiyanto et al., 2020). Penelitian serupa dilakukan dengan menambahkan fitur deteksi untuk nominal uang kertas dollar (Albar & Darmawan, 2021). Perangkat Arduino berhasil diterapkan untuk deteksi nominal rupiah TE 2016 pada nominal Rp100.000, Rp50.000, Rp20.000, dan Rp10.000 dengan output suara terhubung speaker (Alfaraz & Jasril, 2022). Penelitian serupa menerapkan Arduino tidak hanya untuk deteksi nominal uang kertas, namun untuk deteksi keaslian uang kertas (Fatukaloba, 2021). Walaupun perangkat deteksi nominal rupiah berbasis mikrokontroler berhasil dikembangkan, namun penggunaannya kurang efektif karena harus membawa alat-alat tersebut yang ukurannya sangat bervariasi dengan bobot yang berbeda-beda.

Seiring perkembangan teknologi beberapa penelitian menerapkan teknik *computer vision* untuk mendeteksi objek pada berbagai bidang (Aini et al., 2021). Penerapan *computer vision* untuk deteksi nominal rupiah sudah dilakukan oleh beberapa peneliti. Metode *template matching* berhasil diterapkan untuk mendeteksi nominal rupiah TE 2016 berbasis RGB dengan akurasi 100% menggunakan Matlab (Alfita et al., 2022). Penelitian lain berhasil menerapkan metode *optical character recognition* (OCR) untuk deteksi nominal rupiah TE 2016 menggunakan Matlab dengan akurasi 94% (Wanda Hamidah et al., 2022). Penggunaan Matlab pada kedua metode tersebut kurang cocok diterapkan pada aplikasi *mobile*.

Perkembangan teknik *computer vision* untuk deteksi objek saat ini mengarah pada penggunaan algoritma *you only look once* (YOLO) yang berbasis *convolutional neural network* (CNN) (Aini et al.,

2021; Alfarizi et al., 2023). Algoritma CNN untuk mendeteksi nominal rupiah TE 2016 pada nominal Rp50.000 dan Rp100.000 serta uang peringatan kemerdekaan (UPK) pada nominal Rp75.000 dengan total *dataset* citra berjumlah 681 citra berhasil diterapkan. Model diuji dari 5, 10, 15, 20 *epoch* dengan hasil tertinggi sebesar 100% (Octavian Ery Pamungkas et al., 2022). Algoritma CNN juga diterapkan pada deteksi uang kertas rupiah TE 2016 dan TE 2022 dengan arsitektur MobileNetV3 dan algoritma *single shot multibox detector* (SSD). Model yang diusulkan memiliki akurasi 80% hingga 90% pada kondisi pencahayaan memadai (Prima et al., 2022). Algoritma YOLOv3 diterapkan untuk mendeteksi nominal rupiah TE 2016 pada 7 kelas nominal dengan total data 4200 citra dan diimplementasikan ke Android. Hasil penelitian menunjukkan bahwa nilai akurasi berkisar antara 77% hingga 98% tergantung pada pencahayaan (Hermawan et al., 2022). Algoritma YOLOv4-tiny diterapkan untuk mendeteksi nominal uang kertas rupiah TE 2016 pada 7 kelas nominal, dengan total data berjumlah 1700 citra. Metode yang diusulkan memberikan hasil akurasi nilai mAP sebesar 88% dengan waktu *delay* sebesar 1,28 detik (Azhar et al., 2021).

Penelitian lain mengintegrasikan deteksi nominal uang rupiah dengan *output* berupa suara. Algoritma k-Means yang diterapkan di Android digunakan untuk mendeteksi nominal uang kertas rupiah TE 2016. Model diintegrasikan dengan Google Text to Speech untuk membaca *output* hasil deteksi dalam bentuk suara. Akurasi pembacaan Google Text to Speech mencapai 98,6% untuk seluruh bagian uang masuk ke dalam *frame*, 92,5% untuk setengah sisi bagian kanan, dan 98,6% untuk setengah sisi bagian kiri (Arrizqi et al., 2021).

Berdasarkan penelitian-penelitian di atas deteksi nominal rupiah dengan *output* suara sangat membantu penyandang disabilitas netra dalam mengenali nominal uang rupiah. Namun demikian, pada penelitian sebelumnya deteksi nominal rupiah TE 2022 dengan pengambilan citra pada sudut tertentu dan kombinasi *dataset* belum dilakukan. Maka penelitian ini akan mengimplementasikan algoritma YOLOv5 untuk mengetahui tingkat presisi ketika mendeteksi citra nominal uang rupiah emisi 2022 pada sudut pengambilan citra 120° dengan kombinasi *dataset* citra (*citra multi class* dan *citra background*) serta *Google Text to Speech* sebagai *output* suara.

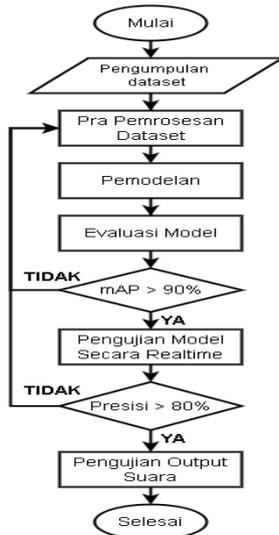
BAHAN DAN METODE

Metode untuk deteksi citra nominal uang kertas rupiah emisi 2022 adalah *deep learning*

dengan algoritma YOLOv5. Tahapan penelitian disusun mengikuti alur pada Gambar 1.

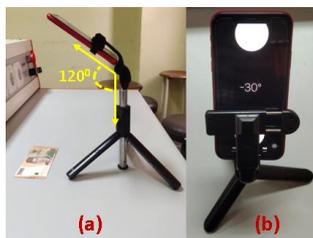
1. Pengumpulan dataset

Dataset utama menggunakan citra uang kertas rupiah emisi 2022, yaitu Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.00. Citra diambil menggunakan perangkat kamera *handphone*, tripod serta aplikasi pengukur sudut yang terpasang di *handphone*.



Sumber: (Hasil Penelitian, 2024)
Gambar 1. Alur Penelitian

Umumnya ketika mengambil citra melalui kamera *handphone* tidak selalu tepat 90° (tegak lurus terhadap objek), tetapi membentuk kemiringan tertentu dengan sudut yang bervariasi. Pada penelitian ini citra diambil dengan sudut 120° (Gambar 2a).



Sumber: (Hasil Penelitian, 2024)
Gambar 2. Pengambilan Citra: (a) Sudut 120°, (b) Aplikasi Pengukur Sudut

Untuk memastikan besar sudut tepat 120° menggunakan pembacaan nilai pada aplikasi pengukur sudut di *handphone*. Jika aplikasi tersebut menunjukkan nilai -30° (Gambar 2b) sama artinya *handphone* sudah menjauh 30° dari titik awal, maka sudut 120° diperoleh dari penjumlahan sudut 90° dengan 30°. Spesifikasi citra yang diambil yaitu

aspek rasio 3:4 atau berukuran 3024x4032, resolusi 9 megapixel dengan *aperture* f/1.8 dan disimpan sebagai *file* bertipe JPEG (Joint Photographic Expert Group).

2. Pra pemrosesan dataset

Dataset utama dikelompokkan menjadi 7 kelas (Tabel 1) nominal, yaitu Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000. Setiap kelas berjumlah 100 citra yang terdiri dari 50 citra “tampak depan” dan 50 citra “tampak belakang”.

Tabel 1. Dataset Utama Citra Rupiah Emisi 2022

No	Nominal (Rp.)	Kuantitas (gambar)	Keterangan
1	1000	100	50 depan, 50 belakang
2	2000	100	50 depan, 50 belakang
3	5000	100	50 depan, 50 belakang
4	10000	100	50 depan, 50 belakang
5	20000	100	50 depan, 50 belakang
6	50000	100	50 depan, 50 belakang
7	100000	100	50 depan, 50 belakang
Total		700	

Sumber: (Hasil Penelitian, 2024)

Dataset tambahan pada Tabel 2, yaitu dataset citra *multi class* dan dataset citra *background*. Tujuan penggunaan dua jenis dataset tambahan ini untuk mengetahui pengaruhnya terhadap nilai presisi model. Jumlah keseluruhan dataset adalah 980 citra

Tabel 2. Dataset Tambahan

No	Citra	Kuantitas (gambar)	Keterangan
1	Multi-Class	250	1 frame memiliki beberapa label kelas
2	Background	30	Citra tanpa ada label dalam 1 frame

Sumber: (Hasil Penelitian, 2024)

Setiap citra dilakukan pelabelan menggunakan perangkat lunak Labeling. Pelabelan ditujukan agar citra dapat diidentifikasi secara otomatis berdasarkan kelasnya pada saat pelatihan dan pengujian. Hasil pelabelan berupa *file plaintext* (txt). Pelabelan dilakukan pada dataset utama dan dataset citra *multi class*, sedangkan dataset citra *background* tidak dilakukan pelabelan.

Tahap akhir pra pemrosesan data adalah pemisahan dataset menjadi data latih dan data uji untuk memvalidasi kinerja model. Pembagian dataset menggunakan perbandingan 80:20, dimana 80% untuk data latih dan 20% untuk data uji.

3. Pemodelan

Pemodelan ditujukan untuk menemukan model deteksi citra uang kertas rupiah emisi 2022

dengan presisi terbaik pada saat pengujian dengan data *realtime*. Pemodelan dilakukan melalui proses pelatihan model. Setiap proses pelatihan dilakukan menggunakan parameter 12 *batch*, 500 *epoch*, dan ukuran piksel 640 untuk mendapatkan nilai mAP tertinggi. Pemodelan memakai algoritma YOLOv5 yang dilatih menggunakan *dataset* citra utama (700 citra), *dataset* citra multi class (250 citra), dan *dataset* citra background (30 citra). Penambahan citra dilakukan secara bertahap selama nilai mAP kurang dari 90%.

4. Pengujian model

Pengujian model dilakukan secara *realtime* dengan mendekati objek uang kertas rupiah emisi 2022 ke kamera *handphone*. Pengujian model menggunakan data *realtime* sebanyak 50 kali untuk setiap kelas nominal. Nilai presisi yang diharapkan yaitu di atas 80%.

5. Metrik Evaluasi

Model dievaluasi menggunakan nilai *mean average precision* (mAP) yang diperoleh dengan perhitungan *intersection over union* (IoU). IoU merupakan ukuran kemiripan dan perbedaan antara suatu citra hasil prediksi dengan citra yang menjadi target.

Nilai IoU memerlukan area irisan atau *intersection* dan area gabungan atau *union* (Azhar et al., 2021). Area irisan adalah area yang dicakup oleh objek yang diprediksi oleh pembatas, sedangkan area gabungan merupakan keseluruhan area dalam satu citra. Perhitungan IoU menggunakan persamaan 1.

$$IoU = \frac{\text{Area Irisan}}{\text{Area Gabungan}} \quad (1)$$

Evaluasi hasil pengujian model dengan data *realtime* berdasarkan *confusion matrix* (Tabel 3). TP (*true positive*) berarti banyak data prediksi yang sesuai dengan data aktual, FP (*false positive*) berarti nilai yang diprediksi salah dari data aktual, FN (*false negative*) berarti nilai yang dihasilkan positif namun diprediksi negatif, TN (*true negative*) berarti nilai yang diprediksi negatif aktual (Octavian Ery Pamungkas et al., 2022).

Confusion matrix	Aktual		
	True	False	
Prediksi	True	TP	FP
	False	FN	TN

Sumber: (Octavian Ery Pamungkas et al., 2022)

Pengujian dengan data *realtime* dilakukan sebanyak 50 kali untuk setiap kelas nominal. Jadi

nilai yang diperoleh adalah TP (nominal kelas aktual yang diprediksi benar) dan FP (nominal kelas aktual yang diprediksi salah), sehingga evaluasi dilakukan dengan menghitung nilai presisi menggunakan persamaan 2.

$$\text{presisi} = \frac{TP}{FP+TP} \times 100\% \quad (2)$$

6. Pengujian output suara

Pengujian *output* suara dilakukan dengan menerapkan model dengan nilai presisi tertinggi ke aplikasi *Google Text to Speech*. Pengujian dilakukan secara *realtime* untuk setiap kelas dan dilakukan sebanyak 50 kali. Tingkat keberhasilan dihitung berdasarkan perbandingan jumlah berhasil dengan total seluruh data uji menggunakan persamaan 3.

$$\text{persentase} = \frac{\text{Jumlah Berhasil}}{\text{Total data uji}} \times 100\% \quad (3)$$

HASIL DAN PEMBAHASAN

1. Hasil pengumpulan dan pra pemrosesan dataset

Terdapat dua jenis *dataset* yaitu *dataset* utama yang berisi citra rupiah emisi 2022 (Tabel 1) dan *dataset* tambahan (Tabel 2). Citra *dataset* pada Tabel 1 terdiri dari 7 kelas nominal yaitu Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000 yang diambil dengan sudut 120°. Citra tersebut diambil “tampak depan” dan “tampak belakang”. Contoh hasil pengambilan citra nominal Rp1000 diperlihatkan pada Gambar 3.



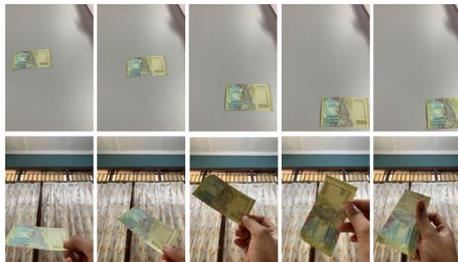
Sumber: (Hasil Penelitian, 2024)

Gambar 3. Pengambilan Citra Nominal Rp1.000 Pada Sudut 120°: (a) Tampak Depan, dan (b) Tampak Belakang

Untuk setiap kelas nominal terdiri dari 50 citra “tampak depan” (Gambar 4) dan 50 citra “tampak belakang” (Gambar 5). Citra “tampak depan” dan “tampak belakang” memiliki dua kelompok citra dengan warna latar belakang *frame* yang berbeda dan masing-masing berjumlah 25 citra. Pada setiap 25 citra objek uang kertas “tampak depan” maupun “tampak belakang” memiliki peletakan posisi berbeda-beda dalam satu *frame*.



Sumber: (Hasil Penelitian, 2024)
 Gambar 4. Sampel Dataset Citra Nominal Rp1000 Tampak Depan Berbagai Posisi Dalam Satu Frame Dengan Latar Belakang Berbeda



Sumber: (Hasil Penelitian, 2024)
 Gambar 5. Sampel Dataset Citra Nominal Rp1000 Tampak Belakang Berbagai Posisi Dalam Satu Frame Dengan Latar Belakang Berbeda

Tujuan penempatan objek uang kertas yang berbeda-beda dalam satu *frame* dan penggunaan warna latar belakang berbeda adalah untuk melatih algoritma YOLOv5 supaya mampu mengklasifikasi citra dengan berbagai macam kondisi.

2. Pelatihan model YOLOv5

Pelatihan model tahap ini menggunakan algoritma YOLOv5 untuk versi YOLOv5s dan YOLOv5m dengan *dataset* Tabel 1 yang berjumlah 700 citra.

Epoch	GPU_mem	box_loss	obj_loss	cls_loss	Instances	Size
499/499	2.82G	0.01405	0.005943	0.0006372	13	640:
	Class	Images	Instances	P	R	mAP50
	all	140	140	0.995	1	0.995

(a)

Epoch	GPU_mem	box_loss	obj_loss	cls_loss	Instances	Size
499/499	5.36G	0.01198	0.005213	0.0004961	13	640:
	Class	Images	Instances	P	R	mAP50
	all	140	140	0.996	0.997	0.995

(b)

Sumber: (Hasil Penelitian, 2024)
 Gambar 6. Hasil Pelatihan Model YOLOv5 700 Citra: (a) YOLOv5s, dan (b) YOLOv5m

Hasil pelatihan (Gambar 6) menunjukkan bahwa YOLOv5s dan YOLOv5m pada *epoch* ke 500 mencapai akurasi mAP sebesar 0.995 (99.5%). YOLOv5s membutuhkan waktu lebih lama 48 menit dibanding YOLOv5s, karena YOLOv5m memiliki kerja pendeteksian objek yang lebih kompleks dari

YOLOv5s. Perbandingan hasil pelatihan model YOLOv5s dengan YOLOv5m disajikan pada Tabel 4.

Tabel 4. Perbandingan Hasil Pelatihan YOLOv5s dan YOLOv5m 700 Citra

Versi	mAP	Waktu Pelatihan
YOLOv5s	0,995 (99,5 %)	1 jam 30 menit
YOLOv5m	0,995 (99,5%)	2 jam 18 menit

Sumber: (Hasil Penelitian, 2024)

Nilai mAP keduanya sebesar 99.5% (Tabel 4) telah melampaui target minimal yaitu 90%. Nilai mAP belum cukup untuk menyatakan kedua model sudah baik dalam mendeteksi citra mata uang rupiah emisi 2022, karena validasi hasil pelatihan model menggunakan *dataset* citra yang memiliki karakteristik mirip dengan *dataset* pelatihan. Kedua model harus diuji menggunakan data yang berbeda.

3. Pengujian realtime model YOLOv5

Pengujian *realtime* untuk model YOLOv5s dan YOLOv5m dilakukan dengan memposisikan uang kertas rupiah emisi 2022 di depan kamera dalam berbagai posisi. Jumlah pengujian untuk setiap kelas nominal dilakukan sebanyak 50 kali.

Tabel 5. Confusion Matrix YOLOv5s 700 Citra

P r e d i k s i	Aktual	Actual						
		Rp k						
Confusion		1	2	5	10	20	50	100
Rp1K		5	-	-	-	38	7	-
Rp2K		48	-	-	-	-	2	-
Rp5K		4	2	-	4	-	40	-
Rp10K		-	-	-	27	-	-	23
Rp20K		39	-	-	-	10	1	-
Rp50K		31	-	-	-	1	18	-
Rp100K		-	-	-	50	-	-	-

Sumber: (Hasil Penelitian, 2024)
 Keterangan: K menyatakan ribu

Hasil pengujian YOLOv5s (Tabel 5) menunjukkan masih banyak terjadi kesalahan deteksi. Nominal Rp1.000 hampir 90% dideteksi sebagai kelas Rp2.000. Begitu pula saat mendeteksi nominal Rp10.000 yang mana 46% dikenali sebagai Rp100.000. Kegagalan deteksi mencapai 100% ketika mendeteksi nominal Rp100.000 yang terdeteksi sebagai kelas Rp10.000. Kegagalan deteksi model disebabkan miripnya fitur citra pada kelas yang berbeda, Misalnya, nominal Rp1.000 dengan Rp2.000 memiliki fitur segi warna yang mirip dan pembeda utama terletak pada gambar wajah pahlawan.

Hasil pengujian lain menunjukkan bahwa saat mendeteksi nominal Rp2.000, Rp20.000, dan Rp50.000 cenderung dideteksi sebagai Rp1.000. Hal tersebut disebabkan model terlalu mengenali fitur kelas Rp1.000 saat proses komputasi.

Tabel 6. Confusion Matrix YOLOv5m 700 Citra

Pre- diksi	Confusion	Aktual						
		Rp K						
Rp1K	27	-	-	-	-	23	-	-
Rp2K	30	-	-	-	-	4	16	-
Rp5K	-	1	-	-	9	-	40	-
Rp10K	1	-	-	-	42	-	-	7
Rp20K	22	-	-	-	-	28	-	-
Rp50K	42	-	1	-	-	-	7	-
Rp100K	-	-	-	-	49	-	1	-

Sumber: (Hasil Penelitian, 2024)

Keterangan: K menyatakan ribu

Hasil pengujian YOLOv5m (Tabel 6) memiliki karakteristik kesalahan deteksi seperti pada YOLOv5s. Kemiripan fitur masih menjadi penyebab dalam mendeteksi citra uang rupiah emisi 2022. Perbandingan kinerja model YOLOv5s dengan YOLOv5m (Tabel 7) dilakukan dengan menghitung nilai presisi pada tabel *confusion matrix* masing-masing.

Berdasarkan Tabel 7, kemampuan model YOLOv5m dalam mendeteksi citra jauh lebih baik dibanding YOLOv5s. Nilai presisi yang dihasilkan oleh YOLOv5m hampir dua kali lipat dari YOLOv5s, hal tersebut disebabkan kompleksitas dari YOLOv5m sangat membantu dalam mengenali fitur citra lebih detail. Walaupun YOLOv5m akurasi lebih tinggi, namun nilai presisi hasil pengujian *realtime* belum mencapai target minimal yang diinginkan yaitu 80%, sehingga model ini perlu dilatih kembali dengan *dataset* tambahan

Tabel 7. Perbandingan Akurasi Model YOLOv5s Dengan YOLOv5m 700 Citra

Kelas	YOLOv5s (Presisi)	YOLOv5m (Presisi)
Rp1K	10%	54%
Rp2K	0%	0%
Rp5K	0%	0%
Rp10K	54%	84%
Rp20K	20%	56%
Rp50K	36%	14%
Rp100K	0%	0%
Rata-Rata	17%	30%

Sumber: (Hasil Penelitian, 2024)

Keterangan: K menyatakan ribu

4. Pelatihan model YOLOv5m dengan *dataset* tambahan

Dataset tambahan (Tabel 2) ada dua kelompok, yaitu citra *multi class* dan citra *background*. Citra *multi class* adalah sebuah citra dimana dalam satu *frame* terdiri lebih dari satu kelas nominal rupiah emisi 2022. Total jumlah citra *multi class* sebanyak 250 citra. Contoh citra *multi class* yang dipakai pada penelitian ini diperlihatkan Gambar 7.



Sumber: (Hasil Penelitian, 2024)

Gambar 7. Contoh Citra Multi Class

Citra *background* adalah sebuah citra dimana dalam satu *frame* tidak memuat label nominal rupiah emisi tahun 2022. Total jumlah citra *background* sebanyak 30 citra. Contoh citra *background* yang dipakai pada penelitian ini diperlihatkan Gambar 8.



Sumber: (Hasil Penelitian, 2024)

Gambar 9. Contoh Citra Background

Pada tahapan ini pelatihan model YOLOv5m dilakukan dengan dua skenario, yaitu (1) melatih model dengan *dataset* 700 citra ditambah *dataset multi class* 250 sehingga total 950 citra, dan (2) melatih model dengan *dataset* 950 citra ditambah *dataset* citra *background* sehingga total 980 citra. Hasil pelatihan model YOLOv5m dengan tambahan *dataset* diperlihatkan pada Gambar 10.

Epoch	GPU_mem	box_loss	obj_loss	cls_loss	Instances	Size
499/499	5.35G	0.01035	0.006196	0.000601	6	640:
	Class	Images	Instances	P	R	mAP50
	all	190	239	0.994	0.988	0.994

(a)

Epoch	GPU_mem	box_loss	obj_loss	cls_loss	Instances	Size
499/499	5.35G	0.01114	0.006528	0.000506	21	640:
	Class	Images	Instances	P	R	mAP50
	all	190	239	0.993	0.988	0.993

(b)

Sumber: (Hasil Penelitian, 2024)

Gambar 10. Hasil Pelatihan Model YOLOv5m: (a) Tambahan Citra Multi Class, dan (b) Tambahan Citra Multi Class dan Background

Pelatihan model YOLOv5m dengan tambahan *dataset* citra *multi class* (Gambar 10a) pada *epoch* ke 500 mencapai akurasi mAP sebesar 0.994 (99.4%) dengan waktu sekitar 3 jam 6 menit, pelatihan model YOLOv5m dengan tambahan *dataset* citra *background* (Gambar 10b) akurasi mAP sebesar 0.993 (99.3%). Kedua model butuh waktu pelatihan lebih lama dibanding ketika melatih model YOLOv5m 700 citra karena tambahan *dataset* yang jumlahnya cukup signifikan. Perbandingan hasil pelatihan model YOLOv5m disajikan pada Tabel 8

Tabel 8. Perbandingan Hasil Pelatihan YOLOv5m Dengan Tambahan Dataset

Dataset	mAP	Waktu Pelatihan
700 Citra	0,995 (99,5 %)	2 jam 18 menit
Multi Class (700 + 250 Citra)	0,994 (99,4%)	3 jam 6 menit
Background (700 + 250+30 Citra)	0,993 (99,3%)	3 jam 6 menit

Sumber: (Hasil Penelitian, 2024)

5. Pengujian *realtime* model YOLOv5m dengan *dataset* tambahan citra *multi class*

Pengujian model dilakukan sebanyak 50 kali untuk setiap kelas nominal pada setiap model YOLOv5m. Hasil pengujian (Tabel 9) menunjukkan bahwa penambahan *dataset* citra *multi class* mampu membantu kinerja pendeteksian citra jauh lebih baik dibanding model tanpa citra *multi class*. Pada pendeteksian nominal Rp50.000 dan Rp20.000 nilai presisi sebesar 100%, nominal Rp1.000 nilai presisi sebesar 90%, nominal Rp2.000 nilai presisi sebesar 76%, dan nominal Rp10.000 nilai presisi sebesar 54%. Citra *multi class* membantu model menghitung nilai *confidence* tiap label dalam satu *frame* dan menemukan nilai *confidence* tertingginya sebagai hasil deteksi nominal citra uji.

Tabel 9. Confusion Matrix YOLOv5m Dengan Tambahan Dataset Multi Class (950 Citra)

Prediksi	Confusion	Aktual							
		Rp 1K	Rp 2K	Rp 5K	Rp 10K	Rp 20K	Rp 50K	Rp 100K	
Rp1K	45	-	-	-	4	1	-		
Rp2K	10	38	-	-	2	-	-		
Rp5K	-	-	-	-	-	50	-		
Rp10K	-	-	-	27	-	-	23		
Rp20K	-	-	-	-	50	-	-		
Rp50K	-	-	-	-	-	50	-		
Rp100K	-	-	-	49	-	1	-		

Sumber: (Hasil Penelitian, 2024)

Keterangan: K menyatakan ribu

Namun, model masih gagal mendeteksi nominal Rp5.000 dan Rp100.000 dimana tingkat keberhasilan sebesar 0%. Model mengenali nominal

Rp5.000 sebagai kelas Rp50.000 dan Rp100.000 sebagai Rp10.000. Hal ini dikarenakan kedua kelas tersebut mempunyai kemiripan fitur terutama warna, nominal, dan ukuran yang tidak terlalu signifikan perbedaannya. Jadi masih terlalu banyak *false positive* (FP) yang dihasilkan.

6. Pengujian *realtime* model YOLOv5m dengan *dataset* tambahan citra *background*

Hasil pengujian pada Tabel 10 menunjukkan bahwa penambahan *dataset* citra *background* pada model YOLOv5m 950 citra mampu meningkatkan kinerja model dalam mendeteksi nominal rupiah emisi 2022. Jika model sebelumnya nominal Rp5.000 dan Rp100.000 gagal terdeteksi sama sekali, maka dengan penambahan citra *background* nominal Rp5.000 berhasil dideteksi dengan tingkat presisi mencapai 88% dan nominal Rp100.000 tingkat presisi mencapai 84%. Citra *background* mampu mengurangi hasil deteksi *false positive* (FP), sehingga nilai presisi meningkat.

Tabel 10. Confusion Matrix YOLOv5m Dengan Tambahan Dataset Multi Class dan Background (980 Citra)

Prediksi	Confusion	Aktual							
		Rp 1K	Rp 2K	Rp 5K	Rp 10K	Rp 20K	Rp 50K	Rp 100K	
Rp1K	41	-	-	-	9	-	-		
Rp2K	6	40	4	-	-	-	-		
Rp5K	-	-	44	-	-	6	-		
Rp10K	-	-	-	32	-	-	18		
Rp20K	-	-	-	-	50	-	-		
Rp50K	7	-	4	-	-	39	-		
Rp100K	-	-	-	8	-	-	42		

Sumber: (Hasil Penelitian, 2024)

Keterangan: K menyatakan ribu

Secara keseluruhan model YOLOv5m dengan tambahan *dataset* citra *multi class* dan citra *background* dengan total data berjumlah 980 citra menghasilkan rata-rata nilai presisi tertinggi, yaitu sebesar 82% seperti yang terlihat pada tabel 11.

Tabel 11. Perbandingan Akurasi Model YOLOv5m Dengan Tambahan Dataset

Kelas	YOLOv5m		
	700 Citra (presisi)	950 Citra (presisi)	980 Citra (presisi)
Rp1K	54%	90%	82%
Rp2K	0%	76%	77%
Rp5K	0%	0%	88%
Rp10K	84%	54%	64%
Rp20K	56%	100%	100%
Rp50K	14%	100%	78%
Rp100K	0%	0%	84%
Rata-Rata	30%	60%	82%

Sumber: (Hasil Penelitian, 2024)

Keterangan: K menyatakan ribu

7. Pengujian Output Suara

Pengujian *output* suara hasil deteksi citra dilakukan sebanyak 50 kali untuk setiap kelas nominal secara *realtime* menggunakan model YOLOv5m 980 citra terhubung pada aplikasi Google Text to Speech.. Total data pengujian berdasarkan Tabel 12 berjumlah 350 data, dengan jumlah keberhasilan sebanyak 286 data dan jumlah kegagalan sebanyak 64 data. Besarnya nilai persentase keberhasilan *output* suara secara keseluruhan dihitung menggunakan persamaan 3.

Tabel 12. Hasil Pengujian Output Suara Model YOLOv5m 980 Citra

Kelas	Berhasil	Gagal
Rp1000	41	9
Rp2000	38	12
Rp5000	39	11
Rp10000	36	14
Rp20000	50	0
Rp50000	40	10
Rp100000	42	8
Total	286	64

Sumber: (Hasil Penelitian, 2024)

$$\text{persentase keberhasilan} = \frac{286}{350} \times 100\% = 82\%$$

Persentase keberhasilan pengujian *output* suara dengan Google Text to Speech sebesar 82%. Nilai tersebut di atas target minimal yang ditetapkan dalam penelitian, yaitu sebesar 80%. Kesamaan persentase nilai *output* suara dengan nilai presisi model mengindikasikan bahwa sistem yang dibangun sudah sesuai.

Jika dibandingkan dengan dengan penelitian deteksi citra rupiah emisi 2022 (Prima et al., 2022), dimana nilai persentasenya berkisar antara 80%-90%, maka persentase deteksi citra pada penelitian ini yang sebesar 82% masih tidak lebih baik dari penelitian sebelumnya. Hal tersebut dikarenakan pada penelitian ini *dataset* citra yang digunakan ditetapkan pada sudut pengambilan 120°, sedangkan pada penelitian sebelumnya pengambilan citra ditekankan pada kondisi pencahayaan yang memadai.

KESIMPULAN

Penelitian ini menerapkan algoritma YOLOv5m untuk mendeteksi citra uang kertas rupiah emisi 2022 dengan *dataset* citra utama berjumlah 700 yang diambil pada sudut 120°. Model yang dihasilkan memiliki nilai mAP yang tinggi yaitu sebesar 99%, tetapi nilai presisi dalam mengenali citra hanya sebesar 30%. Penambahan *dataset* citra *multi class* ke dalam *dataset* citra utama mampu

meningkatkan *confidence* model dalam mendeteksi citra sehingga nilai presisi menjadi 60%. Kemudian, penambahan lagi *dataset* citra *background* dapat mengurangi *false positive*, sehingga nilai presisi meningkat menjadi 82%. Model diuji secara *realtime* dengan mendekatkan uang kertas rupiah emisi 2022 di depan kamera dengan *output* suara menggunakan Google Text to Speech memiliki persentase keberhasilan sebesar 82%, yang berarti sudah sesuai dengan presisi dari model. Penelitian ini berhasil menerapkan algoritma YOLOv5m yang terintegrasi dengan Google Text to Speech untuk mendeteksi citra uang kertas rupiah emisi 2022, namun presisinya hanya sebesar 82%. Keterbatasan dari penelitian ini adalah *dataset* citra utama yang digunakan hanya diambil pada sudut 120° menggunakan kamera *handphone*. Pada penelitian selanjutnya perlu diteliti ada tidaknya korelasi antara perbedaan sudut pengambilan *dataset* citra terhadap besarnya nilai presisi deteksi objek. Selain itu, dalam pengambilan *dataset* citra perlu juga mempertimbangkan kondisi pencahayaan dan kualitas kamera yang digunakan.

REFERENSI

- Aini, Q., Lutfian, N., Kusumah, H., & Zahran, M. S. (2021). Deteksi dan Pengenalan Objek Dengan Model Machine Learning: Model Yolo. *CESS (Journal of Computer Engineering, System and Science)*, 6(2), 192-199. <https://doi.org/https://doi.org/10.24114/ce ss.v6i2.25840>
- Albar, R., & Darmawan, A. (2021). Alat Deteksi Nominal Uang Kertas Rupiah & Dollar Bagi Penyandang Tunanetra Berbasis Arduino Uno. *Journal of Informatics*, 7(1), 46-55. <https://doi.org/10.33143/JICS.VOL7.ISS1.1388>
- Alfaraz, M., & Jasril, I. R. (2022). Rancang Bangun Alat Deteksi Nominal Uang Kertas Penyandang Tuna Netra Berbasis Arduino Uno. *Voteteknika (Vocational Teknik Elektronika Dan Informatika)*, 10(1), 28. <https://doi.org/10.24036/voteteknika.v10i1.116455>
- Alfarizi, D. N., Pangestu, R. A., Aditya, D., Setiawan, M. A., & Rosyani, P. (2023). Penggunaan Metode YOLO Pada Deteksi Objek: Sebuah Tinjauan Literatur Sistematis. *AI Dan SPK: Jurnal Artificial Intelligent Dan Sistem Penunjang Keputusan*, 1(1), 54-63. <https://jurnalmahasiswa.com/index.php/aidanspk/article/view/144>
- Alfita, R., Ibadillah, A. F., & Prianto, A. (2022). Identifikasi Nilai Nominal Uang Kertas

- Berdasarkan Warna Berbasis Image Processing Menggunakan Metode Template Matching. *Jurnal Teknik Elektro Dan Komputer TRIAC*, 9(1), 28–32. <https://doi.org/10.21107/TRIAC.V9I1.12487>
- Arrizqi, N., Santoso, I., & Soetrisno, Y. A. A. (2021). Implementasi Google Text To Speech Pada Aplikasi Pendeteksi Uang Berbasis Android. *Transient: Jurnal Ilmiah Teknik Elektro*, 10(3), 510–516. <https://doi.org/10.14710/transient.v10i3.510-516>
- Azhar, K. M., Santoso, I., & Soetrisno, Y. A. A. (2021). Implementasi Deep Learning Menggunakan Metode Convolutional Neural Network Dan Algoritma Yolo Dalam Sistem Pendeteksi Uang Kertas Rupiah Bagi Penyandang Low Vision. *Transient: Jurnal Ilmiah Teknik Elektro*, 10(3), 502–509. <https://doi.org/10.14710/transient.v10i3.502-509>
- Fatukaloba, R. (2021). Sistem Alat Bantu Jalan Dan Deteksi Nominal Uang Kertas Menggunakan Sensor Ultrasonic Dan Sensor Warna Dengan Output Suara Bagi Penyandang Tuna Netra Berbasis Mikrokontroler. *Informatika: Jurnal Teknik Informatika Dan Multimedia*, 1(1), 55–69. <https://doi.org/10.51903/INFORMATIKA.V1I1.31>
- Hafiar, H., Setianti, Y., Subekti, P., & Sani, A. (2020). Blind Code pada Uang Kertas Rupiah Pesan Komunikasi dan Komunikasi Pesan kepada Publik Disabilitas Netra. *Jurnal Kawistara*, 10(3), 328. <https://doi.org/10.22146/kawistara.48865>
- Hermawan, A., Lianata, L., Junaedi, & Maranto, A. R. K. (2022). Implementasi Machine Learning Sebagai Pengenal Nominal Uang Rupiah dengan Metode YOLOv3. *SATIN - Sains Dan Teknologi Informasi*, 8(1), 12–22. <https://doi.org/10.33372/stn.v8i1.816>
- Hertanto, A. R. (2022). *Fitur Blind Code Mudahkan Tunanetra Kenali Uang Rupiah Kertas Tahun Emisi 2022*. Kediri Nusantara. <https://kedirinusantara.com/29/10/2022/fitur-blind-code-mudahkan-tunanetra-kenali-uang-rupiah-kertas-tahun-emisi-2022/>
- Octavian Ery Pamungkas, Puspa Rahmawati, Dhany Maulana Supriadi, Natasya Nur Khalika, Thofan Maliyano, Dicky Revan Pangestu, Nugraha, E. S., Mas Aly Afandi, Nurcahyani Wulandari, Petrus Kerowe Goran, & Agung Wicaksono1. (2022). Classification of Rupiah to Help Blind with The Convolutional Neural Network Method. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(2), 259–268. <https://doi.org/10.29207/resti.v6i2.3852>
- Prima, A., Santoso, D. B., & Nurpulaela, L. (2022). Deteksi Otomatis Nominal Uang Kertas Rupiah Untuk Tunanetra Menggunakan Algoritma Arsitektur Ssd Mobbilenetv3. *Teknokom*, 6(2), 151–159. <https://doi.org/10.31943/teknokom.v6i2.166>
- Pujianto, A., Abidin, Z., & Utomo, A. B. (2020). Identifikasi Nominal Uang Kertas Untuk Tuna Netra Berbasis Mikrokontroler Dengan Sistem Suara. *JEECOM: Journal of Electrical Engineering and Computer*, 2(2), 1–6. <https://doi.org/10.33650/jeeecom.v2i2.1303>
- Rachma, S. A. (2022). *Terbitkan Uang Baru 2022, Bank Indonesia Dapat Masukan dari Tunanetra*. Liputan6. <https://www.liputan6.com/bisnis/read/5045739/terbitkan-uang-baru-2022-bank-indonesia-dapat-masukan-dari-tunanetra>
- Wanda Hamidah, Irawan, T. S. B., Hasbullah, N. A. P., & Kaswar, A. B. (2022). Deteksi Nominal Uang Kertas Menggunakan OCR (Optical Character Recognition). *Techno Xplore: Jurnal Ilmu Komputer Dan Teknologi Informasi*, 7(2), 72–76. <https://doi.org/10.36805/technoxplore.v7i2.2123>