



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 20754-20763

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Implementasi CNN *Transfer Learning* MobileNetV2 untuk Klasifikasi Mata Uang Rupiah bagi Tunanetra

Hafid Yahya, Elfi Fauziah

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang

hapidyahya01@gmail.com, dosen00475@unpam.ac.id

Abstrak

Pengenalan nominal uang masih menjadi hambatan nyata bagi penyandang tunanetra, terutama ketika uang kertas dalam kondisi lusuh, terlipat, atau memiliki ukuran fisik yang serupa antar pecahan. Penelitian ini mengembangkan sistem klasifikasi mata uang Rupiah secara real-time berbasis Convolutional Neural Network (CNN) dengan pendekatan transfer learning dua fase menggunakan arsitektur MobileNetV2, yang dirancang untuk membantu pengguna tunanetra melalui deteksi berbasis kamera smartphone. Dataset yang digunakan berjumlah 2.400 citra dalam delapan kelas, mencakup tujuh nominal uang kertas emisi 2022 (Rp1.000–Rp100.000) serta satu kelas non-rupiah, dengan pembagian 70% data latih, 15% data validasi, dan 15% data uji. Proses pelatihan dilakukan dalam dua fase, yaitu pembekuan lapisan backbone diikuti fine-tuning sebagian pada lapisan di atas layer ke-100. Hasil evaluasi terhadap 360 citra uji menunjukkan akurasi keseluruhan sebesar 96,39%, dengan precision, recall, dan f1-score macro average masing-masing sebesar 0,97, 0,96, dan 0,96. Model yang telah dilatih dikonversi ke format TensorFlow Lite dan diintegrasikan ke dalam aplikasi Android dengan mekanisme konsensus voting dan keluaran suara (text-to-speech). Pengujian pengguna terhadap tujuh responden tunanetra di Lembaga Layanan Disabilitas Universitas Pamulang menghasilkan skor penerimaan rata-rata 3,91 dari 5, dengan 72% responden menyatakan sistem membantu hingga sangat membantu dibandingkan metode konvensional. Temuan ini membuktikan bahwa transfer learning berbasis MobileNetV2 menawarkan solusi yang efektif dan efisien secara komputasi untuk pengenalan mata uang bagi penyandang tunanetra.

Kata kunci: Convolutional Neural Network, MobileNetV2, Transfer Learning, Tunanetra, Uang Rupiah

1. Latar Belakang

Disabilitas netra merupakan salah satu kondisi keterbatasan fisik yang berdampak signifikan terhadap kemandirian individu dalam menjalankan aktivitas sehari-hari, termasuk aktivitas transaksi keuangan. Data Lembaga Layanan Disabilitas (LLD) Universitas Pamulang per Oktober 2025 mencatat 71 mahasiswa disabilitas terdaftar, dengan 15 di antaranya merupakan penyandang disabilitas netra. Wawancara terhadap tujuh mahasiswa tunanetra pada lembaga tersebut mengungkap bahwa mayoritas responden masih mengalami kesulitan mengenali nominal uang kertas Rupiah secara mandiri, khususnya pada kondisi uang lusuh atau ketika perbedaan ukuran fisik antar pecahan sulit dibedakan melalui perabaan.

Berbagai teknologi aksesibilitas telah dikembangkan untuk membantu penyandang tunanetra, salah satunya fitur pembaca layar *TalkBack* yang diperkenalkan Google sejak 2009 dan terus disempurnakan hingga terintegrasi dalam *Android Accessibility Suite* [1]. Penerapan *TalkBack* pada konteks pendidikan turut terbukti membantu proses pembelajaran siswa tunanetra [2], sementara studi mengenai adaptasi anak tunanetra terhadap lingkungan sekitar menegaskan pentingnya dukungan teknologi dalam kemandirian fungsional penyandang disabilitas netra [3]. Bank Indonesia juga telah menghadirkan fitur blind code pada uang kertas Rupiah sejak emisi 2004 [4]. Namun demikian, fitur taktil tersebut terbukti kurang efektif bagi individu yang relatif baru kehilangan penglihatan dan masih dalam tahap adaptasi mengenali nominal uang secara mandiri.

Seiring meningkatnya keterjangkauan perangkat *smartphone*, pemanfaatan *deep learning* [5], khususnya *Convolutional Neural Network* (CNN) [6], [7], untuk klasifikasi citra visual menjadi peluang yang semakin terbuka dalam mengatasi keterbatasan tersebut. CNN telah terbukti efektif dalam berbagai tugas pengenalan pola visual, termasuk klasifikasi citra, deteksi objek, dan identifikasi karakteristik visual pada domain yang beragam, seperti deteksi jenis kulit wajah [8] dan berbagai aplikasi *machine learning* berbasis Android lainnya.

1.1. State of the Art

Sejumlah penelitian terdahulu telah mengkaji penerapan CNN untuk pengenalan mata uang, baik untuk tujuan umum maupun secara khusus ditujukan bagi penyandang tunanetra. Sadewa dan Yamasari [9] menerapkan *deep transfer learning* dengan arsitektur VGG16 untuk mengklasifikasikan tujuh nominal uang kertas Rupiah emisi 2022 menggunakan 840 citra, memperoleh akurasi pengujian 92,86% serta secara eksplisit merekomendasikan eksplorasi arsitektur *MobileNet* untuk penelitian mendatang. Hidayat dkk. [10] mengembangkan aplikasi *Android* berbasis VGG-16 khusus bagi pengguna tunanetra dengan keluaran suara, mencapai akurasi 83% pada pengujian aplikasi langsung, namun arsitektur yang digunakan tergolong berat secara komputasi untuk perangkat *mobile*. Mahendra [11] mengembangkan model CNN berbasis Keras untuk uang emisi 2009 dan 2016 dengan akurasi validasi 93%, tetapi tidak menasar pengguna tunanetra maupun berbasis *real-time*. Hermana dkk. [12] menerapkan arsitektur *MobileNetV3-Small hybrid* untuk mendeteksi keaslian uang Rupiah berdasarkan fitur *watermark*, mencapai akurasi terbaik 84% pada pecahan Rp100.000, namun penelitian ini berfokus pada autentikasi uang, bukan pada aksesibilitas tunanetra. Ridlo [13] menerapkan *transfer learning MobileNetV2* pada domain berbeda (klasifikasi ras kucing) namun membuktikan keunggulan efisiensi inferensi arsitektur tersebut pada perangkat *mobile*, mencapai akurasi 92% dengan waktu inferensi hanya 75–85 ms per *frame*. Azhar dkk. [14] menerapkan kombinasi CNN dan algoritma YOLO untuk mendeteksi uang kertas Rupiah secara *real-time* bagi penyandang *low vision*, namun pendekatan deteksi objek tersebut memerlukan anotasi *bounding box* yang lebih kompleks dibandingkan klasifikasi murni berbasis CNN yang diterapkan pada penelitian ini.

Penelitian pada domain internasional turut memperkuat relevansi pendekatan berbasis *MobileNetV2* untuk aksesibilitas tunanetra. Ewwiekpaefe dan Isacha [15] mengembangkan aplikasi *mobile* pengenalan mata uang berbasis *MobileNetV2* bagi tunanetra dengan hasil klasifikasi yang kompetitif namun belum diuji langsung pada pengguna tunanetra sungguhan. Meedin [16] membandingkan delapan arsitektur *transfer learning*, termasuk *MobileNetV2*, untuk deteksi uang kertas Sri Lanka, dengan *DenseNet121* sebagai model performa terbaik, meski kompleksitas komputasi lebih tinggi dibanding *MobileNetV2*. Park dan Park [17] merancang model deteksi multinasional (*multinational banknote detecting model*) yang mendukung berbagai mata uang sekaligus namun tidak difokuskan pada satu mata uang secara mendalam. Nasir dkk. [18] menerapkan CNN untuk pengenalan mata uang Pakistan bagi tunanetra dengan pendekatan klasifikasi konvensional. Ghanem dkk. [19] mengusulkan pendekatan berbasis YOLO untuk pengenalan mata uang Mesir bagi tunanetra dengan akurasi deteksi tinggi, namun pendekatan berbasis deteksi objek ini memerlukan anotasi *bounding box* yang lebih kompleks dibandingkan klasifikasi murni berbasis CNN. Selain pada domain mata uang, arsitektur *MobileNetV2* juga telah banyak diterapkan pada berbagai domain klasifikasi citra lain, seperti identifikasi pemilahan sampah [20] dan deteksi daun herbal berbasis *Android* [21], yang keduanya turut membuktikan konsistensi keunggulan *MobileNetV2* dalam efisiensi komputasi pada berbagai kasus penggunaan *mobile*.

Table 1 Ringkasan Penelitian Terdahulu

Peneliti (Tahun)	Metode/Objek	Hasil	Kelemahan
Sadewa & Yamasari [9] (2024)	VGG16, Uang Rupiah	Akurasi uji 92,86%	Bukan tunanetra; rekomendasi MobileNet
Hidayat dkk. [10] (2023)	VGG-16 Android, tunanetra	Akurasi 83%	Arsitektur berat komputasi
Mahendra [11] (2022)	CNN Keras, Uang Rupiah	Akurasi validasi 93%	Bukan tunanetra, non-mobile
Hermana dkk. [12] (2026)	MobileNetV3-Small, watermark	84%	Fokus keaslian, bukan aksesibilitas
Ridlo [13] (2026)	MobileNetV2, ras kucing	Akurasi 92%, 75–85 ms	Domain berbeda (bukan uang)
Ewwiekpaefe & Isacha [15] (2024)	MobileNetV2, mata uang tunanetra	Akurasi kompetitif	Belum diuji pengguna nyata
Meedin [16] (2023)	Multi-TL, Uang Sri Lanka	DenseNet121 terbaik, 98%	Model terbaik lebih berat dari MobileNetV2
Park & Park [17] (2023)	Multinational banknote model	Dukung banyak mata uang	Kurang mendalam per mata uang
Nasir dkk. [18] (2024)	CNN, Uang Pakistan tunanetra	Klasifikasi akurat	Evaluasi pengguna terbatas
Ghanem dkk. [19] (2025)	YOLOv8/v9/v10, Uang Mesir	mAP 0,9934 (YOLOv10)	Perlu anotasi bounding box, kompleks
Azhar dkk. [14]	CNN + YOLO	mAP 97,65%	Perlu anotasi bounding box, kompleks

1.2. Research Gap dan Kontribusi Penelitian


Berdasarkan Tabel 1, dapat diidentifikasi celah penelitian (*research gap*) yang jelas: penelitian yang secara khusus menasar pengguna tunanetra pada domain mata uang Rupiah masih menggunakan arsitektur CNN yang relatif berat secara komputasi (VGG-16) [10], sementara penelitian yang telah memanfaatkan *MobileNetV2* untuk efisiensi mobile justru diterapkan pada domain berbeda [13] atau belum divalidasi melalui pengujian langsung terhadap pengguna tunanetra [15]–[18]. Sadewa dan Yamasari [9] bahkan secara eksplisit merekomendasikan eksplorasi arsitektur *MobileNet* untuk penelitian klasifikasi uang Rupiah selanjutnya, namun rekomendasi tersebut belum ditindaklanjuti dengan validasi empiris terhadap pengguna tunanetra nyata.

Penelitian ini memberikan kontribusi dengan mengimplementasikan CNN berbasis *transfer learning* dua fase menggunakan arsitektur *MobileNetV2* secara khusus untuk klasifikasi mata uang Rupiah emisi 2022, diintegrasikan ke dalam aplikasi *mobile Android* berbasis kamera *smartphone* dengan keluaran suara, serta divalidasi melalui pengujian langsung terhadap tujuh mahasiswa tunanetra di Lembaga Layanan Disabilitas Universitas Pamulang, sehingga menghasilkan bukti empiris mengenai efektivitas teknis sekaligus tingkat penerimaan pengguna nyata, sebuah kombinasi yang belum ditemukan secara utuh pada penelitian-penelitian sebelumnya.

Tujuan penelitian ini adalah: (1) mengimplementasikan dan melatih model CNN dengan pendekatan *transfer learning MobileNetV2* untuk mengenali nominal mata uang Rupiah; (2) mengevaluasi tingkat akurasi, *precision*, *recall*, dan *f1-score* model; (3) mengimplementasikan model ke dalam aplikasi *mobile* berbasis kamera *smartphone*; dan (4) mengukur tingkat penerimaan pengguna tunanetra melalui pengujian langsung dan kuesioner.

2. Metode Penelitian


Penelitian ini menggunakan metode eksperimen kuantitatif untuk pengembangan dan evaluasi model klasifikasi berbasis *deep learning*, dikombinasikan dengan model pengembangan sistem *Waterfall* untuk perancangan aplikasi *mobile*. Tahapan penelitian meliputi studi literatur, pengumpulan data, pra-pemrosesan data, perancangan arsitektur model, pelatihan dan evaluasi model, implementasi sistem, serta pengujian dan evaluasi pengguna.



Gambar 1 Diagram Alur Penelitian

2.1. Dataset dan Akuisisi Data

Dataset yang digunakan terdiri atas 2.400 citra uang kertas Rupiah emisi 2022 dalam delapan kelas, mencakup tujuh nominal (Rp1.000 hingga Rp100.000) serta satu kelas non-rupiah yang berisi objek selain uang kertas (gelas, latar belakang, lantai, tangan kosong) sebagai mitigasi terhadap *overconfidence* model, mengingat penelitian ini tidak menerapkan *object detection* melainkan murni klasifikasi berbasis CNN. Setiap kelas terdiri atas 300 citra dengan rasio 1:1, diperoleh melalui pengambilan gambar mandiri menggunakan kamera *smartphone* pada kondisi pencahayaan terang, redup, dan latar belakang yang bervariasi guna meningkatkan *robustness* model terhadap kondisi nyata di lapangan.



Gambar 2 Sampel Dataset Gambar Uang Rupiah Emisi 2022

Variasi tersebut mencakup kondisi uang terlipat, lusuh, serta sudut pengambilan yang berbeda, sehingga model dilatih untuk mengenali pola visual yang konsisten meski dalam kondisi yang tidak ideal.

Dataset kemudian dibagi menjadi data latih (70%, 1.680 citra), data validasi (15%, 360 citra), dan data uji (15%, 360 citra) untuk memastikan evaluasi model dilakukan secara objektif pada data yang belum pernah dipelajari model.

2.2. Pra-pemrosesan Data

Sebelum digunakan untuk pelatihan model CNN, seluruh data gambar melalui tahap pra-pemrosesan [22]: (1) pembersihan data duplikat melalui perhitungan nilai *hash* untuk menghindari bias pelatihan; (2) *resize* citra menjadi 224×224 piksel sesuai dimensi *input layer* *MobileNetV2*; (3) normalisasi piksel dari rentang 0–255 menjadi 0–1 untuk mempercepat konvergensi; dan (4) augmentasi data berupa rotasi, *flipping horizontal/vertikal*, *zoom*, dan penyesuaian kecerahan untuk mengurangi risiko *overfitting* serta meningkatkan generalisasi model.

2.3. Arsitektur Model CNN

Model dibangun menggunakan pendekatan *transfer learning* dengan *MobileNetV2* sebagai *backbone*, memanfaatkan bobot (*weights*) yang telah dilatih pada dataset *ImageNet* sehingga model tidak perlu dilatih dari awal (*from scratch*), dan tetap memberikan performa tinggi meskipun dataset yang tersedia relatif terbatas [23]. Pemilihan *MobileNetV2* sebagai arsitektur *backbone* didasarkan pada perbandingan performa dengan arsitektur *lightweight* lain seperti *EfficientNet-B3*, di mana *MobileNetV2* terbukti memberikan keseimbangan yang lebih baik antara akurasi dan efisiensi komputasi pada perangkat dengan sumber daya terbatas [24]. Arsitektur tersusun atas: *input layer* ($224 \times 224 \times 3$), *MobileNetV2 backbone* tanpa *top layer* sebagai ekstraktor fitur, *global average pooling*, dua lapisan *dense* (512 dan 256 neuron) masing-masing dengan *batch normalization* dan *dropout* (0,4 dan 0,3), serta *output layer dense* 8 kelas dengan fungsi aktivasi *softmax*.

2.4. Strategi Pelatihan Dua Fase

Pelatihan model dalam penelitian ini dilakukan dalam dua fase untuk mengoptimalkan performa model sekaligus mencegah *overfitting*, mengikuti pendekatan *fine-tuning* bertahap yang telah terbukti efektif pada penelitian *transfer learning* sebelumnya [25]. Pada fase pertama, seluruh lapisan *backbone* dibekukan (*freeze*) dan hanya *classifier head* yang dilatih selama maksimal 10 *epoch* dengan *learning rate* $1e-3$. Pada fase kedua (*fine-tuning*), lapisan *backbone* dibuka sebagian mulai dari *layer* ke-100 hingga *layer* terakhir (*partial unfreeze*), dilatih selama maksimal 20 *epoch* dengan *learning rate* yang jauh lebih kecil ($1e-5$) agar pembaruan bobot berlangsung stabil. Ketiga mekanisme *callback*, *ModelCheckpoint*, *EarlyStopping*, dan *ReduceLROnPlateau* diterapkan pada kedua fase untuk mengontrol proses pelatihan secara otomatis berdasarkan nilai *val_accuracy* dan *val_loss*.

2.5. Strategi Pelatihan Dua Fase

Validasi dilakukan pada setiap *epoch* menggunakan 360 citra data validasi untuk memantau performa model selama pelatihan. Setelah pelatihan selesai, model terbaik dievaluasi menggunakan 360 citra data uji yang belum pernah dilihat model, melalui metrik akurasi, *precision*, *recall*, *f1-score* per kelas (*classification report*), serta analisis *confusion matrix* dan Grad-CAM untuk interpretabilitas model.


2.6. Implementasi Sistem Mobile

Model yang telah dilatih dikonversi ke format *TensorFlow Lite* (TFLite) agar dapat berjalan secara lokal pada perangkat tanpa koneksi internet. Sistem diimplementasikan sebagai aplikasi *Android* berbasis bahasa pemrograman *Kotlin* (minimum *Android* 11), diuji pada perangkat *Samsung Galaxy A50s*. Aplikasi *mobile* menerapkan mekanisme voting konsensus 4 dari 5 *frame* dengan ambang *confidence* 85% sebelum menghasilkan keluaran suara (*text-to-speech*) nominal uang, guna mencegah kesalahan deteksi akibat *noise* pada *frame* tunggal.

3. Hasil dan Diskusi

3.1. Hasil Pelatihan

Pelatihan model CNN dilakukan menggunakan *Google Colaboratory* dengan akselerasi *GPU T4*, menerapkan pendekatan *transfer learning* dua fase dengan total 30 *epoch* (10 *epoch* fase pembekuan *backbone*, 20 *epoch* fase *fine-tuning*). Riwayat pelatihan keseluruhan ditunjukkan pada grafik berikut.



Gambar 3 Visualisasi *Training History* CNN Transfer Learning MobileNetV2

Grafik tersebut memperlihatkan lonjakan *train loss* yang wajar pada awal fase *fine-tuning* (*epoch* ke-11), diikuti penurunan *val_loss* yang stabil hingga *epoch* terakhir, mengindikasikan model tidak mengalami *overfitting* meski *backbone* dibuka sebagian.

Pada fase pertama, model terbaik dicapai pada *epoch* ke-6 dengan *val_accuracy* 93,89%, sementara mekanisme *ReduceLROnPlateau* menurunkan *learning rate* dari $1e-3$ menjadi $5e-4$ pada *epoch* ke-9 akibat *val_loss* yang stagnan. Pada fase kedua, dengan 54 lapisan *trainable* dari total 154 lapisan *backbone*, model terbaik diperoleh pada *epoch* ke-13 dengan *val_accuracy* 95,83%, tanpa aktivasi *EarlyStopping* karena performa terus meningkat secara konsisten hingga mendekati *epoch* akhir.


3.2. Hasil Evaluasi Model

Evaluasi terhadap 360 citra data uji menghasilkan akurasi keseluruhan sebesar 96,39% (347 dari 360 citra terklasifikasi benar), melampaui target akurasi minimal 85% yang ditetapkan sebagai kebutuhan non-fungsional sistem. Hasil ini juga melampaui performa penelitian sejenis, yakni Hidayat dkk. [10] (83%), Sadewa dan Yamasari [9] (94,29%), dan Ridlo [13] (92%), menunjukkan bahwa kombinasi arsitektur *MobileNetV2* dengan strategi *fine-tuning partial unfreeze* pada penelitian ini memberikan keseimbangan optimal antara efisiensi komputasi dan akurasi klasifikasi.

Table 2 Classification Report Model CNN

Kelas	Precision	Recall	F1-Score	Support
Rp 1.000	1.00	0.89	0.94	45
Rp 2.000	0.83	1.00	0.91	45
Rp 5.000	1.00	0.93	0.97	45
Rp 10.000	0.96	0.96	0.96	45
Rp 20.000	0.98	0.98	0.98	45
Rp 50.000	0.98	0.96	0.97	45
Rp 100.000	1.00	1.00	1.00	45
Non-Rupiah	1.00	1.00	1.00	45
Macro Avg	0.97	0.96	0.96	360
Weighted Avg	0.97	0.96	0.96	360

Hasil *classification report* menunjukkan performa sempurna (*f1-score* 1,00) pada kelas Rp100.000 dan Non Rupiah, serta performa sangat baik pada kelas Rp20.000 (*f1-score* 0,98). Kelas Rp2.000 menunjukkan *precision* terendah (0,83) meski *recall*-nya sempurna (1,00), mengindikasikan model tidak pernah gagal mengenali uang Rp2.000 yang sebenarnya, namun beberapa citra dari kelas lain cenderung salah diklasifikasikan sebagai Rp2.000. Pola kesalahan klasifikasi antar kelas divisualisasikan melalui *confusion matrix* berikut.




Gambar 4 Visualisasi *Confusion Matrix* Klasifikasi Rupiah Emisi 2022

Kelas Rp2.000 menerima jumlah *false positive* tertinggi (9 sampel) dari kelas lain, sementara kelas Rp100.000 dan Non Rupiah tidak menunjukkan kesalahan klasifikasi sama sekali, mengonfirmasi konsistensi hasil dengan *classification report* pada Tabel 2.

3.3. Analisis Grad-CAM dan Interpretabilitas Model

Untuk memahami dasar pengambilan keputusan model, dilakukan analisis *Gradient-weighted Class Activation Mapping* (Grad-CAM). Area citra yang menjadi fokus perhatian model divisualisasikan sebagai berikut.



Gambar 5 Visualisasi Grad-CAM pada Uang Rp50.000

Model secara konsisten memfokuskan perhatian pada area wajah tokoh pahlawan dan angka nominal uang kertas, ditandai aktivasi tinggi pada area tersebut. Fenomena ini membuktikan bahwa model belajar mengenali fitur visual yang relevan secara semantik, bukan sekadar pola tekstur atau warna latar yang tidak informatif, sehingga mendukung keandalan model dalam kondisi pengambilan citra yang bervariasi.

Evaluasi kualitatif melalui prediksi pada sampel data uji turut menunjukkan bahwa model mampu mengklasifikasikan dengan benar berbagai kondisi uang yang menantang, termasuk uang terlipat, digenggam tangan, kondisi pencahayaan rendah, serta posisi miring pada gambar 6 memperkuat *robustness* model terhadap variasi kondisi nyata di lapangan.



Gambar 6 Visualisasi Prediksi pada *Sample Test Set*

Sebagian besar sampel menghasilkan tingkat kepercayaan prediksi di atas 93%, bahkan beberapa mencapai 100%, menunjukkan konsistensi model dalam mengenali karakteristik visual setiap nominal. Selain itu, model juga berhasil mengidentifikasi objek yang bukan merupakan uang Rupiah (non-rupiah) dengan tingkat kepercayaan 54,7%, sehingga tidak memenuhi ambang kepercayaan (*confidence threshold*) yang ditetapkan. Hasil tersebut menunjukkan bahwa mekanisme klasifikasi tidak hanya mampu mengenali uang Rupiah, tetapi juga membantu mengurangi potensi keluaran yang keliru ketika objek yang diamati bukan merupakan target klasifikasi.

3.4. Implementasi Sistem *Mobile*

Model yang telah dilatih dikonversi ke format *TensorFlow Lite* dan diintegrasikan ke dalam aplikasi *Android* berbasis bahasa *Kotlin*, diuji pada perangkat *Samsung Galaxy A50s* (*Android* 11). Aplikasi menerapkan mekanisme deteksi kontinu dengan konsensus voting 4 dari 5 *frame* dan ambang *confidence* 85% sebelum menghasilkan keluaran suara nominal uang melalui *text-to-speech*, sehingga risiko kesalahan keluaran suara akibat *noise* pada *frame* tunggal dapat diminimalkan. Sebagai contoh, pada pengujian objek non-rupiah dengan *confidence* rendah (54,7%), mekanisme ambang batas tersebut berhasil mencegah keluaran suara yang tidak akurat. Hasil implementasi fitur utama dapat dilihat pada gambar 7



Gambar 7 Layar Utama

Gambar 7 menunjukkan antarmuka utama aplikasi *Android* yang telah mengintegrasikan model *TensorFlow Lite* untuk melakukan klasifikasi nominal uang Rupiah secara *real-time*. Informasi hasil deteksi ditampilkan dalam bentuk nominal uang, nilai *confidence*, dan margin sebagai indikator keyakinan model. Pada contoh pengujian, sistem berhasil mengidentifikasi uang pecahan Rp10.000 dengan *confidence* sebesar 88,5%, sedangkan fitur *Flash* disediakan untuk membantu proses deteksi pada kondisi pencahayaan yang kurang optimal.

3.5. Pengujian Sistem

Pengujian *black box* terhadap seluruh modul fungsional aplikasi (autentikasi, deteksi kamera, keluaran suara) menunjukkan bahwa seluruh skenario pengujian berjalan sesuai hasil yang diharapkan. Pengujian *white box* pada modul autentikasi *login* menggunakan perhitungan *Cyclomatic Complexity* menghasilkan nilai $V(G)=7$ dengan tujuh jalur independen, seluruhnya berhasil diverifikasi tanpa kegagalan logika.

3.6. Pengujian Pengguna

Pengujian penerimaan pengguna melibatkan tujuh mahasiswa tunanetra di LLD Universitas Pamulang, terdiri atas tiga responden tunanetra total dan empat responden *low vision*.

Table 3 Hasil Kuesioner Skala *Likert*

No	Pernyataan	Skor Responden	Rata-rata
1	Aplikasi mudah digunakan	4, 4, 4, 4, 5, 4, 5	4.29
2	Instruksi suara mudah dipahami	3, 2, 2, 2, 4, 5, 5	3.29
3	Hasil suara nominal uang terdengar jelas	5, 2, 2, 2, 5, 5, 5	3.71
4	Proses pengenalan uang berlangsung cepat.	5, 5, 3, 4, 5, 2, 5	4.14
5	Aplikasi membantu mengenali nominal uang dengan lebih mudah	5, 5, 3, 3, 4, 1, 5	3.71
6	Saya dapat menggunakan aplikasi secara mandiri	5, 4, 4, 4, 5, 4, 5	4.43
7	Aplikasi bermanfaat dalam aktivitas sehari-hari	5, 5, 3, 3, 5, 3, 5	4.14
8	Merasa lebih percaya diri saat bertransaksi tunai	4, 4, 4, 3, 4, 2, 5	3.71
9	Puas dengan aplikasi yang telah dikembangkan	4, 2, 3, 3, 4, 2, 5	3.29
10	Bersedia menggunakan aplikasi jika tersedia secara umum	5, 4, 4, 4, 5, 4, 5	4.43
Rata-rata keseluruhan			3.91

Hasil kuesioner Skala *Likert* menunjukkan skor rata-rata keseluruhan 3,91 dari skala 5, dikategorikan sebagai tingkat penerimaan baik. Skor tertinggi diperoleh pada pernyataan kemandirian penggunaan aplikasi dan kesediaan menggunakan aplikasi secara umum (masing-masing 4,43), sementara skor terendah pada kejelasan instruksi suara dan kepuasan keseluruhan (masing-masing 3,29), mengindikasikan area perbaikan pada kualitas keluaran *text-to-speech*.

Sebanyak 72% responden menyatakan aplikasi membantu hingga sangat membantu dibandingkan metode konvensional (meraba tekstur uang atau meminta bantuan orang lain), dan seluruh responden (100%) berhasil mencoba berbagai nominal secara mandiri. Temuan kesalahan deteksi yang dilaporkan responden pada nominal Rp1.000 dan Rp2.000 konsisten dengan hasil evaluasi kuantitatif model, di mana kedua kelas tersebut memang memiliki *precision/recall* terendah dibanding kelas lain, memperkuat validitas silang antara evaluasi teknis model dan pengalaman pengguna nyata.

3.7. Perbandingan dengan Penelitian Sebelumnya

Dibandingkan dengan Hidayat dkk. [10] yang menggunakan VGG-16 dan mencapai akurasi 83% pada pengujian aplikasi langsung, penelitian ini mencapai akurasi lebih tinggi (96,39%) dengan arsitektur yang jauh lebih ringan secara komputasi. Dibandingkan Ridlo [13] yang menerapkan *MobileNetV2* pada domain berbeda, penelitian ini membuktikan bahwa keunggulan efisiensi arsitektur tersebut juga berlaku pada domain klasifikasi mata uang. Kelebihan utama penelitian ini terletak pada kombinasi efisiensi komputasi, akurasi tinggi, dan validasi langsung terhadap pengguna tunanetra nyata. Keterbatasan penelitian ini meliputi jumlah responden pengujian pengguna yang relatif kecil (tujuh orang) serta kelas Rp1.000 dan Rp2.000 yang masih menunjukkan tingkat kesalahan klasifikasi lebih tinggi dibanding kelas lain.

4. Kesimpulan

Model *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning* dua fase menggunakan arsitektur *MobileNetV2* berhasil mencapai akurasi klasifikasi sebesar 96,39% pada 360 data uji, dengan model terbaik diperoleh pada *epoch* ke-13 fase *fine-tuning* (*val_accuracy* 95,83%) tanpa indikasi *overfitting*. Hasil *classification report* dan *confusion matrix* menunjukkan performa sempurna pada kelas Rp100.000 dan Non Rupiah, sementara kelas Rp2.000 menjadi kelas dengan tingkat kesalahan klasifikasi tertinggi akibat kemiripan visual dengan nominal lain. Analisis Grad-CAM membuktikan model belajar mengenali fitur visual yang relevan secara semantik, yaitu area wajah tokoh dan angka nominal pada uang kertas, bukan sekadar pola tekstur yang tidak informatif. Model yang telah dikembangkan berhasil diimplementasikan ke dalam aplikasi *mobile Android* berbasis kamera *smartphone* dengan keluaran suara, sehingga mampu membantu penyandang disabilitas tunanetra mengenali nominal uang Rupiah secara mandiri tanpa memerlukan koneksi internet. Pengujian penerimaan pengguna terhadap tujuh responden tunanetra di Lembaga Layanan Disabilitas Universitas Pamulang menunjukkan tingkat penerimaan baik dengan skor rata-rata 3,91 dari skala 5, di mana 72% responden menyatakan aplikasi membantu hingga sangat membantu dibandingkan metode konvensional, dan seluruh responden mampu mengoperasikan aplikasi secara mandiri. Temuan kesalahan deteksi yang dilaporkan pengguna pada nominal Rp1.000 dan Rp2.000 konsisten dengan hasil evaluasi kuantitatif model, sehingga memperkuat validitas hasil penelitian secara keseluruhan.

Referensi

- [1] C. Chen, S. Ganov, and T. V. Raman, "TalkBack: An Open Source Screenreader For Android," Google. Accessed: Jul. 12, 2026. [Online]. Available: <https://opensource.googleblog.com/2009/10/talkback-open-source-screenreader-for.html>
- [2] A. Hermawan, L. Yaum, and R. Megaswarie, "PENERAPAN APLIKASI TALKBACK DALAM PELAKSANAAN PEMBELAJARAN SISWA TUNANETRA KELAS XI DI SLB NEGERI BRANJANGAN JEMBER," *J. Pendidik. Inklusi Citra Bakti*, vol. 1, pp. 109–116, Aug. 2023, doi: <https://doi.org/10.38048/jpicb.v1i1.2208>.
- [3] N. Simanjuntak, R. L. Ginting, M. P. Setianta, N. A. Salsabila, and S. Hidayah, "Proses Adaptasi Anak Tunanetra Terhadap Lingkungan Masyarakat," *J. Inov. Penelit. Ilmu Pendidik. Indones.*, vol. 2, no. Vol 2, No 1, Januari 2025, pp. 80–85, 2025, doi: <https://doi.org/10.31004/e16a3520>.
- [4] CNN Indonesia, "Soal Janji Uang Braille, BI Punya Blind Code Sejak 2004," CNN Indonesia. Accessed: Jul. 12, 2026. [Online]. Available: <https://www.cnnindonesia.com/nasional/20181118052451-32-347439/soal-janji-uang-braille-bi-punya-blind-code-sejak-2004>
- [5] R. Ardianto and S. K. Wibisono, "Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum," *J. Kolaboratif Sains*, vol. 6, no. Vol. 6 No. 12: DESEMBER 2023, pp. 2081–2092, 2023, doi: [10.56338/jks.v6i12.4938](https://doi.org/10.56338/jks.v6i12.4938).
- [6] C. Juliandy and Darwin, "Pengenalan Computer Vision Berbasis Convolutional Neural Network melalui DewataTalks," *Sarwahita J. Pengabd. Kpd. Masy.*, vol. 21, no. Vol. 21 No. 01 (2024): Sarwahita : Jurnal Pengabdian Kepada Masyarakat, pp. 45–52, 2024, doi: <https://doi.org/10.21009/sarwahita.211.4>.
- [7] M. M. Taye, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," *Multidiscip. Digit. Publ. Inst.*, vol. 11, no. 3, 2023, doi: <https://doi.org/10.3390/computation11030052>.
- [8] A. P. Gani and E. Poerwandono, "PENGEMBANGAN APLIKASI ANDROID BERBASIS MACHINE LEARNING UNTUK PENDETEKSI JENIS KULIT WAJAH MENGGUNAKAN DEEP LEARNING," *J. Mhs. Tek. Inform.*, vol. 9, no. 6, pp. 9551–9557, 2025, doi: <https://doi.org/10.36040/jati.v9i6.15674>.
- [9] B. A. Sadewa and Y. Yamasari, "Implementasi Deep Transfer Learning untuk Klasifikasi Nominal Uang Kertas Rupiah," *J. Informatics Comput. Sci.*, vol. 5, no. Vol. 5 No. 04 (2024), pp. 543–551, 2024, doi: <https://doi.org/10.26740/jinacs.v5n04.p543-551>.
- [10] A. M. N. Hidayat, A. Antamil, and I. Z. M, "Identifikasi Nominal Mata Uang Rupiah Bagi Penyandang Tunanetra Dengan Algoritma Convolutional Neural Network Berbasis Android," *J. Software, Hardware, Inf. Technol.*, vol. 3, no. No. 2 (2023), pp. 60–65, 2023, doi: <https://doi.org/10.24252/shift.v3i2.102>.
- [11] I. M. Gede and I. Mahendra, "Pengembangan Model Pembelajaran Mesin untuk Mengidentifikasi Nominal Uang Kertas Rupiah Menggunakan Algoritma CNN Dengan Library Keras," vol. 8, no. Vol 8 No 1 (2022): Kalbisiana, pp. 469–475, 2022, [Online]. Available: <https://ojs.kalbis.ac.id/index.php/kalbisiana/id/article/view/290/225>
- [12] A. N. Hermana, A. W. Tetuko, and M. G. Husada, "Identifikasi Keaslian Uang Rupiah menggunakan Arsitektur MobilenetV3-Small Hybrid Berdasarkan Watermark," *J. Innov. Creat.*, vol. 6, no. Vol. 6 No. 1 (2026), pp. 9539–9545, 2026, doi: <https://doi.org/10.31004/joecy.v6i1.8055>.
- [13] M. U. Ridlo, "Klasifikasi Ras Kucing Real-Time Pada Android Menggunakan Transfer Learning MobileNetV2," *Pros. Semin. Nas. Teknol. DAN SAINS*, vol. 5, no. Vol. 5 No. 1 (2026): Seminar Nasional Teknologi & Sains (STAINS), pp. 336–343, 2026, doi: <https://doi.org/10.29407/wp0kct24>.
- [14] 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," *Transient J. Ilm. Tek. Elektro*, vol. 10, no. 3, 2021, pp. 502–509, 2021, doi: <https://doi.org/10.14710/transient.v10i3.502-509>.
- [15] A. E. Evwiekpaefe and H. Isacha, "A Visually Impaired Mobile Application for Currency Recognition using MobileNetV2 CNN Architecture," *J. Comput. Soc. Informatics*, vol. 4, no. No. 1, 2025, pp. 26–42, 2025, doi: <https://doi.org/10.33736/jcsi.8562.2025>.
- [16] A. S. K. Perera and G. S. N. Meedin, "Fine-tuned CNN-based Sri Lankan Currency Note Detection Method for the Visually Impaired People Using Smartphones," *Inst. Electr. Electron. Eng.*, 2023, doi: <https://doi.org/10.1109/ICARC57651.2023.10145672>.
- [17] C. Park and K. R. Park, "MBDM: Multinational Banknote Detecting Model for Assisting Visually Impaired People," *Multidiscip. Digit. Publ. Inst.*, vol. 11, no. Mathematics 2023, 11(6), 1392, 2023, doi: <https://doi.org/10.3390/math11061392>.
- [18] A. Nasir, S. Zafar, and Z. Nasir, "Pakistani Currency Recognition and Classification for Visually Impaired People Using Convolutional Neural Network," *IEEE*, vol. 4, no. Conference: 2024 4th International Conference on Digital Futures and Transformative Technologies (ICoDT2), 2024, doi: <https://doi.org/10.1109/ICoDT262145.2024.10740188>.
- [19] A. M. Ghanem, H. A. Youness, M. Wahba, and H. M. Abdelaal, "Recognizing Egyptian currency for people with visual impairment using deep learning models," *Sci. Rep.*, vol. 15, no. Scientific Reports volume 15, Article number: 34288 (2025), pp. 1–15, 2025, doi: <https://doi.org/10.1038/s41598-025-20646-x>.
- [20] S. E. Thio and J. Susilo, "Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0," *Bin. Digit. - Technol.*, vol. 8, no. Vol. 8 No. 1 (2025): bit-Tech, pp. 2622–271X, 2025, doi: <https://doi.org/10.32877/bt.v8i1.1900>.
- [21] R. Osgibran, "Deteksi Daun Herbal Berbasis Android Menggunakan Transfer Learning MobileNetV2," *Pros. Semin. Nas. Teknol. DAN SAINS*, vol. 5, no. Vol. 5 No. 1 (2026): Seminar Nasional Teknologi & Sains (STAINS), pp. 179–186, 2026, doi: <https://doi.org/10.29407/5b3jst33>.
- [22] Y. Yuhandri, A. Ramadhani, and H. Syahputra, "PENGENALAN TEKNOLOGI PENGOLAHAN CITRA DIGITAL (DIGITAL IMAGE PROCESSING) UNTUK SANTRI DI RAHMATAN LIL ' ALAMIN INTERNATIONAL ISLAMIC BOARDING SCHOOL," *Community Dev. J.*, vol. 3, no. Community Development Journal Jurnal Pengabdian Masyarakat 3(2):1239-1244, pp. 1239–1244, 2022, doi: <https://doi.org/10.31004/cdj.v3i2.5868>.
- [23] I. F. Annur, J. Umami, M. N. Annafii, and N. Trisnaningrum, "Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetV2," *Fountain Informatics J.*, vol. 8, no. Fountain of Informatics Journal 8(1):7-14, pp. 7–14, 2023, doi: <https://doi.org/10.21111/fij.v8i1.9419>.
- [24] Y. Miftahuddin and F. Z. S, "Perbandingan Metode Efficientnet-B3 dan Mobilenet-V2 Untuk Identifikasi Jenis Buah-buahan Menggunakan Fitur Daun," *J. Ilm. Teknol. Infomasi Terap.*, vol. 9, no. December 2022Jurnal Ilmiah Teknologi Infomasi Terapan 9(1), pp. 1–11, 2022, doi: <https://doi.org/10.33197/jitter.v9i1.2022.911>.
- [25] F. Muhammad, A. M. Arimurthy, and D. Chahyati, "Transfer Learning dengan Metode Fine Tuning pada Model Network VGG16 dan ResNet50," *Indones. J. Comput. Sci.*, vol. 12, no. February 2023Indonesian Journal of Computer Science 12(1), pp. 361–374, 2023, doi: <https://doi.org/10.33022/ijcs.v12i1.3130>.

DOI: <https://doi.org/10.31004/riggs.v5i2.12446>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)