TECHNOVATAR Jurnal Teknologi, Industri dan Informasi
Vol. 5, No. 1, Januari 2027, pp. 1 – 11
Open Access: https://journal.awatarapublisher.com/index.php/technovatar
ISSN: 3031-8874, **DOI**: 10.61434/technovatar.v5i1.444

RUPIAHVISION: MODEL PENGENALAN RUPIAH BERBASIS MOBILENETV2 UNTUK DISABILITAS NETRA DAN KESENJANGAN KINERJA DUNIA NYATA

Ahmad Ngiliyun[1], M. M. Irfan Subakti[2], Rendi Agus Sucipto[3], Nikolas Febrianto[4], Ika Nurfitriani[5]

[1,3,4,5] Peserta Pijak in collaboration with IBM Skillsbuild, Indonesia
[2] Departemen Teknik Informatika, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia

e-mail: ahmadngiliyun@gmail.com[1], irfan@its.ac.id[2], apq000d6y0559@student.devacademy.id[3], apq000d6y0563@student.devacademy.id[4], apq000d6x0565@student.devacademy.id[5]

INFO ARTIKEL
Sejarah Artikel:
Diterima, 10 November 2026
Direvisi, 15 November 2026
Disetujui, 17 November 2026

KEYWORDS
Rupiah banknote recognition
Transfer learning
MobileNetV2
Accessibility
Domain shift

ABSTRACT

Visually impaired people often cannot distinguish Rupiah banknote denominations, and classifiers that score well on internal test data may still fail on everyday photographs. This study built RupiahVision, a mobile Rupiah recognizer, and measured the gap between internal and real-world performance. A pretrained MobileNetV2 with a frozen backbone and an eight-class head was trained on 3,173 images combining a public Kaggle dataset with the team's photographs, then served through FastAPI to a React Native application. Evaluation used 485 internal test images and 259 separately prepared real-world photographs. Internal accuracy reached 92.99%, whereas real-world accuracy was only 48.65%. Errors concentrated on the Rp2,000 prediction (91 of 259 predictions) and Rp20,000, while the non-banknote class kept a recall of 0.95. Internal accuracy alone therefore cannot establish readiness; training data diversity and consistent preprocessing at serving time should be prioritized. Results come from a single training run and 259 test photographs and are therefore indicative.

This work is licensed under a Creative Commons Attribution 4.0 International License.

KATA KUNCI
Pengenalan uang Rupiah
Transfer learning
MobileNetV2
Aksesibilitas
Pergeseran domain

CORRESPONDING AUTHOR
Ahmad Ngiliyun
Peserta Pijak in collaboration with IBM Skillsbuild
Indonesia
ahmadngiliyun@gmail.com

ABSTRAK

Penyandang disabilitas netra sulit membedakan nominal uang kertas Rupiah, sementara model pengenalan citra yang akurat pada data uji internal belum tentu andal pada foto sehari-hari. Penelitian ini membangun RupiahVision, aplikasi seluler pengenal nominal Rupiah, dan mengukur kesenjangan kinerja antara uji internal dan uji dunia nyata. Model MobileNetV2 praterlatih dengan *backbone* dibekukan dan kepala klasifikasi delapan kelas dilatih pada 3.173 citra gabungan dataset Kaggle dan foto tim, lalu dilayani melalui FastAPI untuk aplikasi React Native. Evaluasi memakai 485 citra uji internal dan 259 foto dunia nyata yang disiapkan terpisah. Akurasi uji internal mencapai 92,99%, sedangkan akurasi dunia nyata hanya 48,65%. Kesalahan menumpuk pada prediksi Rp2.000 (91 dari 259 prediksi) dan Rp20.000, sedangkan kelas Bukan_Uang tetap terdeteksi dengan *recall* 0,95. Akurasi uji internal karenanya tidak cukup sebagai bukti kesiapan; keragaman data latih dan keseragaman praproses penyajian perlu diprioritaskan. Hasil berasal dari satu kali pelatihan dan 259 foto uji sehingga bersifat indikatif.

PENDAHULUAN

Uang tunai tetap dipakai dalam transaksi sehari-hari, dan keberhasilan bertransaksi bergantung pada kemampuan mengenali nominal uang kertas. Bagi penyandang disabilitas netra dan orang dengan penglihatan rendah, kemampuan ini tidak selalu tersedia, padahal kebutaan dan gangguan penglihatan dialami oleh jutaan orang di dunia dan menjadi persoalan kesehatan masyarakat yang terus berlanjut (Bourne *et al.*, 2021). Hambatan tersebut membuat penyandang disabilitas netra bergantung pada bantuan orang lain ketika menerima kembalian atau membayar, sehingga teknologi bantu yang dapat menyebutkan nominal secara mandiri memiliki nilai praktis yang jelas.

Kamera ponsel pintar memungkinkan pengenalan nominal dijalankan tanpa perangkat khusus. Fadlurrahman *et al.* (2025) mengembangkan pengenal Rupiah berbasis pembelajaran mesin seluler untuk pengguna dengan gangguan penglihatan, Kumara *et al.* (2024) memakai YOLOv8 pada tongkat pintar untuk mendeteksi nominal Rupiah, dan Alfatikarani *et al.* (2025) memanfaatkan *transfer learning* VGG-19 untuk mendeteksi uang Rupiah bagi penyandang disabilitas netra. Pada ranah internasional, Khalil *et al.* (2022) menyajikan klasifikasi mendalam seluler untuk uang kertas Uni Emirat Arab bagi pengguna dengan hambatan penglihatan. Secara lebih luas, penerapan *computer vision* pada perangkat pengguna juga telah ditelaah secara sistematik pada konteks pengalaman wisatawan di destinasi pintar (Panigrahy dan Verma, 2025).

MobileNetV2 dirancang untuk perangkat dengan sumber daya terbatas melalui *inverted residual* dan *linear bottleneck* (Sandler *et al.*, 2018), sedangkan *transfer learning* memungkinkan bobot hasil pelatihan awal dipakai ulang ketika data target terbatas (Zhuang *et al.*, 2021). Pada data sekecil proyek ini, membekukan *backbone* menekan biaya komputasi dan risiko *overfitting*, tetapi membatasi kemampuan model menyesuaikan fitur dengan domain baru, dan pertukaran inilah yang diuji pada penelitian ini. Pembelajaran mesin juga telah dimanfaatkan pada berbagai persoalan klasifikasi dan prediksi di lingkungan lokal, misalnya prediksi capaian akademik mahasiswa (Malik *et al.*, 2026), klasifikasi sentimen ulasan berbahasa Indonesia (Rosmawan *et al.*, 2026), analisis data pertandingan olahraga (Permana *et al.*, 2026), prediksi hasil pertandingan permainan daring (Ngiliyun, 2026), dan pengembangan aplikasi pembelajaran seluler (Ngiliyun *et al.*, 2026). Namun, studi-studi tersebut tidak menangani pengenalan citra uang untuk aksesibilitas, dan sebagian besar kajian pengenalan uang yang ditinjau lebih menonjolkan rancangan model daripada ukuran kesenjangan antara data uji dan penggunaan nyata. Arsitektur ringan bergaya seluler serupa juga dipakai pada tugas citra lain, misalnya segmentasi rambut pada citra dermoskopi dengan Mobile U-Net (Kostidjan *et al.*, 2026).

Kesenjangan itu penting karena akurasi yang dilaporkan pada data uji yang dipisah secara acak dari sumber yang sama dapat terlalu optimistis ketika pengguna memotret di lingkungan yang berbeda, sebab distribusi data berubah antara tahap pelatihan dan penggunaan (Zhuang *et al.*, 2021). Aplikasi bantu juga harus menolak objek yang bukan uang kertas, persoalan yang dalam literatur dikenal sebagai deteksi *out-of-distribution* (Yang *et al.*, 2024). Artikel ini menangani kedua persoalan tersebut pada kasus RupiahVision, aplikasi seluler pengenal nominal Rupiah yang dikembangkan sebagai proyek akhir program pembelajaran intensif.

Tujuan penelitian ini ada tiga. Pertama, membangun alur lengkap pengenalan nominal Rupiah dari pengumpulan data hingga aplikasi seluler. Kedua, mengevaluasi model pada dua tingkat, yaitu uji internal dan uji dunia nyata, lalu mengukur selisih kinerjanya beserta pola kesalahan yang muncul. Ketiga, menyatakan secara terbuka keterbatasan sistem agar klaim kesiapan aplikasi tidak melampaui bukti. Kontribusi artikel ini ialah pelaporan dua tingkat evaluasi yang jujur pada sistem pengenal Rupiah berbasis ponsel, disertai analisis kesalahan dan rekomendasi perbaikan yang dapat diuji pada penelitian lanjutan.

METODE PENELITIAN

Rancangan penelitian

Penelitian ini berupa pengembangan sistem terapan dengan evaluasi empiris dua tingkat, yaitu uji internal pada data yang dipisahkan dari kumpulan latih dan uji dunia nyata pada foto yang disiapkan terpisah. Pekerjaan dilakukan oleh tim PJK-GU105 sebagai proyek akhir program Pijak in collaboration with IBM SkillsBuild. Pelatihan dan evaluasi dijalankan pada Google Colab dengan PyTorch, sedangkan konversi model dan layanan inferensi dibangun pada tahap penyajian yang diuraikan di bagian akhir bab ini.

Dataset

Dataset gabungan berisi 3.173 citra dalam delapan kelas, yaitu tujuh nominal Rupiah (Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000) serta kelas Bukan_Uang. Sumber utama ialah dataset publik Rupiah Banknotes Dataset di Kaggle (anidwiastuti, n.d.) berisi 2.398 citra uang kertas emisi 2016 dengan 334 sampai 344 citra per nominal, yang dominan berbentuk persegi atau lanskap dengan resolusi kecil dan seragam. Sumber tambahan ialah 775 foto yang diambil tim dengan ponsel, terdiri atas 349 foto uang kertas dan 426 foto objek selain uang kertas untuk kelas Bukan_Uang. Foto tim dominan berorientasi potret dengan resolusi asli tinggi. Dengan demikian foto tim menyumbang 24,4% dari seluruh citra, dan foto uang kertas tim hanya 12,7% dari 2.747 citra nominal. Berkas berformat HEIC dikonversi ke JPG dengan pustaka pillow-heif sebelum diproses.

Dataset dibagi secara acak dengan pustaka split-folders (*seed* 42) menjadi 2.218 citra latih (70%), 470 citra validasi, dan 485 citra uji. Komposisi per kelas disajikan pada Tabel 1. Pemisahan dilakukan per citra tanpa pengelompokan menurut sumber atau kemiripan, sehingga citra yang nyaris sama dapat berada di himpunan yang berbeda, keterbatasan yang dibahas kemudian. Pemeriksaan duplikat belum dilakukan, sehingga akurasi uji internal perlu dibaca sebagai batas atas yang mungkin optimistis.

Tabel 1 Komposisi dataset per kelas dan pembagian data

Kelas	Total	Latih	Validasi	Uji
Rp1.000	385	269	57	59
Rp2.000	394	275	59	60
Rp5.000	397	277	59	61
Rp10.000	393	275	58	60
Rp20.000	386	270	57	59
Rp50.000	399	279	59	61
Rp100.000	393	275	58	60
Bukan_Uang	426	298	63	65
Jumlah	3.173	2.218	470	485

Sumber: pengolahan data penelitian

Praproses dan augmentasi

Setiap citra diubah ukurannya menjadi 224 x 224 piksel dengan teknik *letterbox*, yaitu skala disamakan terhadap sisi terpanjang dengan interpolasi Lanczos dan sisa area diisi hitam, agar rasio aspek uang kertas tidak terdistorsi. Teknik ini dipilih karena orientasi dan resolusi citra Kaggle berbeda dari foto tim. Pada data latih diterapkan rotasi acak hingga 15 derajat dengan isian hitam

serta perubahan kecerahan dan kontras acak dengan faktor 0,3; pembalikan horizontal tidak dipakai. Semua citra kemudian dinormalisasi dengan rerata dan simpangan baku ImageNet.

Arsitektur dan pelatihan model

Model memakai MobileNetV2 dengan bobot praterlatih ImageNet. Seluruh parameter *backbone* dibekukan, dan hanya kepala klasifikasi yang dilatih, berupa lapisan *dropout* berpeluang 0,2 diikuti lapisan linear dari 1.280 fitur ke 8 kelas. Fungsi kerugian ialah *cross-entropy*, optimizer Adam dengan laju belajar 0,001, ukuran *batch* 32, dan 15 *epoch*. Satu konfigurasi ini yang dilatih; pencarian hiperparameter tidak terdokumentasi pada notebook proyek. Set validasi dipakai untuk memeriksa generalisasi setelah pelatihan, dan set uji internal dipakai satu kali untuk pelaporan akhir.

Evaluasi

Kinerja dihitung dengan akurasi, presisi, *recall*, dan *F1-score* per kelas serta rerata makro dan terbobot dari pustaka scikit-learn, disertai *confusion matrix*. Karena jumlah citra uji per kelas hampir seimbang, kedua jenis rerata nyaris sama, dan akurasi total dilaporkan bersama rerata makro agar kelas yang buruk tidak tersamarkan. Ketidakpastian dinyatakan dengan interval kepercayaan Wilson 95% yang dihitung dari jumlah prediksi benar dan jumlah total. Uji internal memakai 485 citra uji hasil pembagian acak. Uji dunia nyata memakai 259 foto yang disiapkan terpisah dari dataset pelatihan, dikonversi ke JPG, dan diaudit karakteristik latar belakang, pencahayaan, serta estimasi jarak pemotretannya sebagai metadata deskriptif yang belum dipakai untuk analisis kinerja per kondisi, dengan jumlah 29 sampai 42 foto per kelas (Bukan_Uang 42 foto). Evaluasi dunia nyata di notebook memakai praproses *letterbox* yang sama dengan pelatihan.

Perangkat lunak yang dipakai meliputi Python 3.12 pada Google Colab dengan akselerasi GPU, PyTorch untuk pelatihan, scikit-learn untuk metrik, pillow-heif versi 1.4.0 untuk konversi HEIC, onnx2tf untuk konversi TFLite, FastAPI untuk layanan, serta React Native dan Expo untuk aplikasi seluler. Kode notebook dan keluaran evaluasi menjadi sumber seluruh angka pada artikel ini.

Penyajian model dan aplikasi

Model PyTorch diekspor ke ONNX, dikonversi ke TFLite berpresisi *float32* dengan onnx2tf (ukuran 8,5 MiB), lalu disajikan melalui layanan FastAPI yang dipasang di Render. Layanan menerima citra dan mengembalikan label, skor kepercayaan, serta daftar prediksi. Aplikasi seluler dibangun dengan React Native dan Expo (APK versi 1.1) dan memungkinkan pengguna memotret atau memilih citra dari galeri, melihat nominal hasil prediksi, dan membuka riwayat citra. Gambar 1 merangkum alur penelitian dan penyajian, dan Gambar 2 menampilkan antarmuka aplikasi.

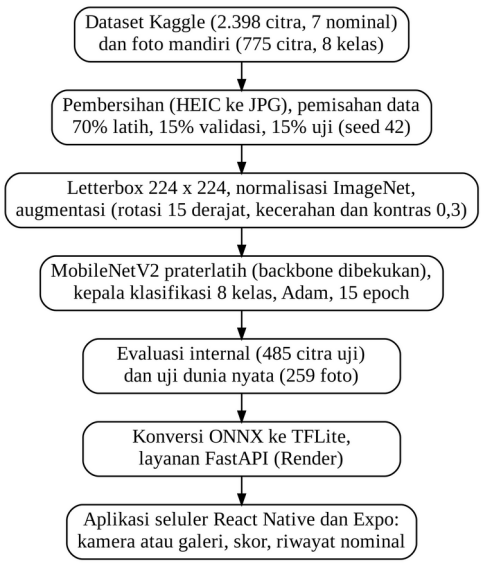

Gambar 1 Alur penelitian dan penyajian RupiahVision

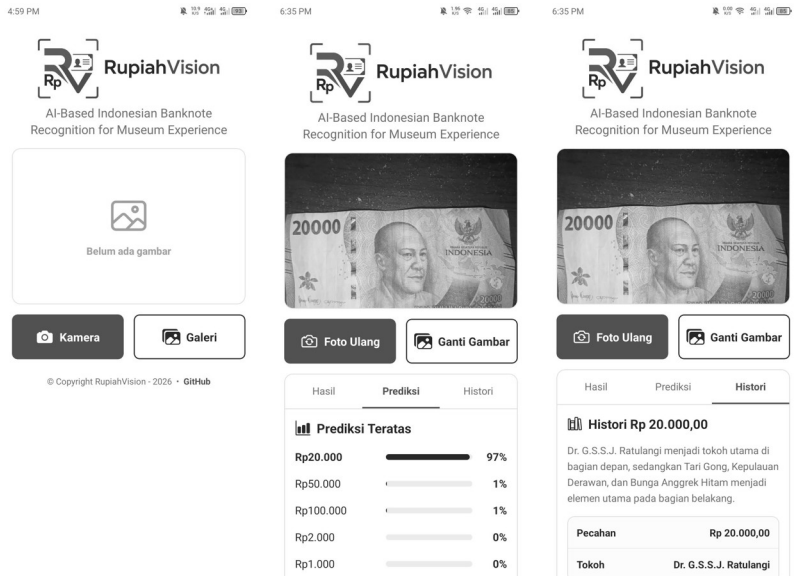

Gambar 2 Antarmuka aplikasi RupiahVision: halaman utama, hasil prediksi, dan riwayat citra (tangkapan layar diubah ke hitam-putih)

DISKUSI DAN PEMBAHASAN

Kinerja pada uji internal

Pada akhir *epoch* ke-15, akurasi latih mencapai 91,25%, sedangkan akurasi validasi 93,19% dan akurasi uji internal 92,99% (451 dari 485 citra benar), interval Wilson 95% 90,4% sampai 94,9%, dengan *F1-score* rerata makro 0,93. Akurasi latih yang sedikit lebih rendah daripada akurasi validasi sejalan dengan adanya augmentasi dan *dropout* hanya pada tahap latih. *Recall* per kelas berkisar dari 0,87 pada Rp10.000 hingga 1,00 pada Bukan_Uang, dan presisi terendah, yaitu 0,88, dijumpai pada Rp20.000 dan Bukan_Uang, sedangkan *F1-score* per kelas berkisar dari 0,91 sampai 0,95. Pada tingkat ini model tampak andal dan seimbang antarkelas, sebagaimana tampak pada Gambar 3 bagian (a).

Dinamika pelatihan memperlihatkan konvergensi yang cepat karena hanya kepala klasifikasi yang diperbarui. Akurasi latih naik dari 52,03% pada *epoch* pertama menjadi 78,54% pada *epoch* kedua dan 84,31% pada *epoch* ketiga, lalu melandai di sekitar 90% mulai *epoch* ke-12 (90,40%, 90,22%, 90,35%, dan 91,25% pada *epoch* ke-12 sampai ke-15), sedangkan kerugian kumulatif per *epoch* turun dari 116,23 menjadi 23,33 (jumlah kerugian seluruh *batch* pada *epoch* bersangkutan). Pelandaian ini menunjukkan bahwa kapasitas kepala linear di atas fitur beku hampir jenuh pada data latih, sehingga penambahan *epoch* kemungkinan tidak banyak membantu tanpa membuka sebagian lapisan *backbone* atau memperkaya data.

Kinerja pada uji dunia nyata

Gambaran berubah tajam pada 259 foto dunia nyata. Akurasi turun menjadi 48,65% (126 dari 259 foto), interval Wilson 95% 42,6% sampai 54,7%, dengan presisi, *recall*, dan *F1-score* rerata makro masing-masing 0,61, 0,47, dan 0,45. Selisihnya terhadap uji internal ialah 44,34 poin persentase. Jika kelas Bukan_Uang dikeluarkan, hanya 86 dari 217 foto uang kertas (39,6%), interval Wilson 95% 33,4% sampai 46,3% yang dikenali nominalnya dengan benar. Tabel 2 memerinci kinerja per kelas, dan Gambar 3 bagian (b) menampilkan sebaran kesalahannya.

Untuk menakar bobot angka tersebut, dua pembanding sederhana dapat dipakai. Dengan delapan kelas yang hampir seimbang, tebakan acak menghasilkan akurasi sekitar 12,5%, dan prediktor yang selalu menjawab Bukan_Uang menghasilkan 16,2% (42 dari 259 foto). Akurasi dunia nyata 48,65% memang jauh di atas kedua pembanding itu, tetapi masih 44,34 poin di bawah uji internal, sehingga model belajar sesuatu yang berguna namun belum cukup andal. Peringkat kelas pun tidak terjaga antartingkat evaluasi. Rp10.000 terlemah pada keduanya (*recall* internal 0,87 dan dunia nyata 0,06) dan Rp20.000 terbaik di antara nominal pada keduanya (0,98 dan 0,84), tetapi Rp1.000 yang berada di urutan kedua pada uji internal (0,95) turun ke urutan keenam pada uji dunia nyata (0,10). Uji internal karenanya tidak hanya melebih-lebihkan tingkat kinerja, tetapi juga kurang mampu memperkirakan kelas mana yang akan gagal di lapangan.

Tabel 2 Kinerja per kelas pada uji internal dan uji dunia nyata

Kelas	Recall internal	Presisi dunia nyata	Recall dunia nyata	F1 dunia nyata
Rp1.000	0,95	0,43	0,10	0,16
Rp2.000	0,90	0,20	0,58	0,30
Rp5.000	0,90	0,71	0,39	0,50
Rp10.000	0,87	0,67	0,06	0,11
Rp20.000	0,98	0,47	0,84	0,60
Rp50.000	0,92	0,71	0,52	0,60
Rp100.000	0,92	1,00	0,33	0,50
Bukan_Uang	1,00	0,73	0,95	0,82

Sumber: laporan klasifikasi hasil evaluasi penelitian

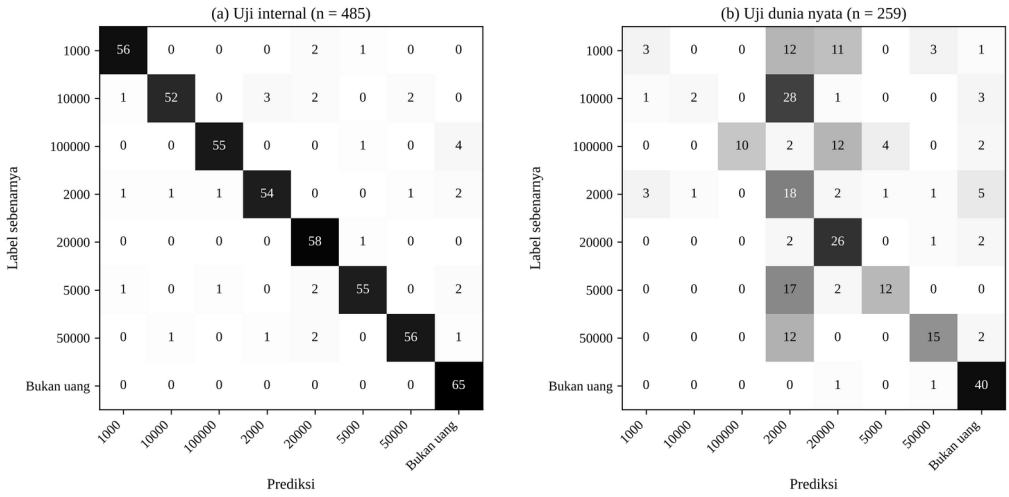

Gambar 3 Confusion matrix: (a) uji internal dan (b) uji dunia nyata (label kelas dalam rupiah)

Pola kesalahan

Kesalahan tidak tersebar acak, melainkan menumpuk pada dua kelas. Sebanyak 91 dari 259 foto (35,1%), dengan interval Wilson 95% 29,6% sampai 41,1%, diprediksi sebagai Rp2.000, padahal hanya 31 foto yang benar-benar berlabel Rp2.000, sehingga presisi kelas ini hanya 0,20. Dari 133 kesalahan, 73 (54,9%) berujung pada prediksi Rp2.000 dan 29 (21,8%) pada prediksi Rp20.000, sehingga dua kelas itu menampung 76,7% seluruh kesalahan. Contoh paling ekstrem ialah Rp10.000, yang *recall*-nya hanya 0,06 karena 28 dari 35 fotonya diprediksi sebagai Rp2.000. Sebaliknya, Rp20.000 memiliki *recall* tinggi (0,84) tetapi presisi hanya 0,47 karena menarik foto nominal lain, termasuk 12 foto Rp100.000 dan 11 foto Rp1.000. Rp100.000 menunjukkan pola unik: presisi 1,00 berarti setiap prediksi Rp100.000 benar, namun *recall* 0,33 berarti dua pertiga fotonya terlewat. Pola kolaps ke satu kelas ini lazim muncul ketika model menerima masukan yang menyimpang dari distribusi latih dan bobot kepala klasifikasi mengarahkan sebagian besar masukan asing ke kelas yang sama (Zhuang *et al.*, 2021).

Arah kesalahan juga penting dalam konteks bantu. Dari 133 kesalahan, 81 (60,9%) menyebut nominal lebih kecil daripada nominal sebenarnya, 35 (26,3%) menyebut nominal lebih besar, 15 (11,3%) menolak uang kertas sebagai bukan uang, dan 2 (1,5%) menyebut objek bukan uang sebagai nominal. Kesalahan yang menyebut nominal lebih kecil merugikan pengguna saat membayar, sedangkan kesalahan yang menyebut nominal lebih besar merugikan pengguna saat menerima kembalian, sehingga keduanya sama-sama berisiko bagi pengguna yang tidak dapat memeriksa uang secara visual. Kecenderungan menyebut nominal lebih kecil muncul terutama karena kolapsnya prediksi ke Rp2.000, nominal terkecil kedua.

Penyebab yang diduga

Penelitian ini tidak menguji sebab-akibat melalui eksperimen ablasi, sehingga beberapa dugaan berikut harus dibaca sebagai hipotesis untuk diuji. Dugaan pertama ialah pergeseran domain. Sebagian besar citra latih berasal dari dataset Kaggle yang seragam dan beremisi tunggal, sedangkan foto dunia nyata dominan berorientasi potret, beresolusi tinggi, dan bervariasi dalam latar belakang serta pencahayaan, sementara porsi foto tim di data latih hanya 24,4%. Dugaan kedua ialah keterbatasan adaptasi, karena *backbone* dibekukan sehingga fitur tingkat rendah dan menengah tidak menyesuaikan diri dengan foto ponsel; hanya kepala klasifikasi berukuran 1.280 x 8 yang belajar. Dugaan ketiga ialah optimisme uji internal akibat pembagian acak per citra, yang memungkinkan

citra hampir identik dari sumber yang sama berada di himpunan latih dan uji. Ketiga dugaan ini sejalan dengan pembahasan *transfer learning* dan pergeseran distribusi pada kajian Zhuang *et al.* (2021), tetapi besarnya kontribusi masing-masing belum terukur.

Pilihan membekukan *backbone* masuk akal untuk model ringan yang dijalankan pada sumber daya terbatas (Sandler *et al.*, 2018) dan untuk data berukuran kecil, tetapi pilihan itu memindahkan seluruh beban adaptasi ke kepala linear. Ketika foto ponsel memiliki statistik tekstur, rasio aspek, dan pencahayaan yang berbeda dari citra Kaggle, kepala tersebut tidak dapat memperbaiki fitur yang sudah terlanjur disaring oleh lapisan beku. Pencahayaan buruk juga ditangani khusus pada tugas citra lain, misalnya melalui pemulihan berbasis peningkatan citra pada verifikasi wajah cahaya rendah (Wahyudi *et al.*, 2026), sehingga pengaruhnya layak diukur terpisah. Penyetelan halus sebagian blok akhir, yang lazim dibahas dalam literatur *transfer learning* (Zhuang *et al.*, 2021), menjadi eksperimen pertama yang layak dilakukan dengan konfigurasi beku ini sebagai pembanding.

Terdapat pula risiko pada tahap penyajian. Praproses di layanan FastAPI yang dipakai aplikasi mengubah ukuran citra secara langsung tanpa padding, sedangkan model dilatih dan dievaluasi dengan *letterbox*. Perbedaan ini dapat menggeser masukan ke model pada penggunaan nyata, sehingga kinerja aplikasi yang sesungguhnya mungkin berbeda dari 48,65% dan belum diukur pada penelitian ini. Klaim artikel ini karena itu dibatasi pada model dengan praproses pelatihan, bukan pada aplikasi secara ujung ke ujung. Pola yang sama antara pelatihan dan penyajian perlu dijamin sebelum klaim apa pun tentang kinerja aplikasi dibuat.

Penanganan objek bukan uang

Kelas Bukan_Uang berfungsi sebagai penolak sederhana atas objek di luar delapan kelas. Kelas ini mencapai *recall* 1,00 dan presisi 0,88 pada uji internal, serta *recall* 0,95 (40 dari 42 foto) dan presisi 0,73 pada uji dunia nyata. Sebanyak 15 dari 217 foto uang kertas (6,9%) keliru ditolak sebagai bukan uang, sedangkan hanya dua foto bukan uang yang lolos sebagai nominal. Dengan demikian pendekatan berbasis kelas ini cukup efektif untuk menyaring objek yang mirip dengan contoh pada 426 foto latih, tetapi belum menjamin penolakan objek asing lain. Layanan yang diperiksa pada penelitian ini tidak menerapkan ambang kepercayaan atau ukuran ketidakpastian seperti entropi untuk menolak prediksi yang meragukan, padahal pendekatan semacam itu lazim dibahas dalam deteksi *out-of-distribution* (Yang *et al.*, 2024).

Perbandingan dengan penelitian terdahulu

Angka kinerja RupiahVision tidak dibandingkan langsung dengan hasil Fadlurrahman *et al.* (2025), Alfatikarani *et al.* (2025), atau Kumara *et al.* (2024), karena data uji, jumlah kelas, dan protokol evaluasi berbeda. Tabel 3 merangkum pendekatan studi yang ditelaah berdasarkan judul dan metadata publikasinya. Kesamaan yang dapat dicatat ialah pemanfaatan bobot praterlatih dan arsitektur citra pada perangkat bergerak, seperti pada Alfatikarani *et al.* (2025) yang memakai VGG-19 dan Khalil *et al.* (2022) yang menyasar klasifikasi seluler. Bagi pengembang aplikasi bantu, pelajaran praktisnya ialah bahwa akurasi uji internal 92,99% saja tidak cukup untuk menyatakan sistem siap dipakai oleh penyandang disabilitas netra, sebab satu nominal yang salah disebut dengan percaya diri dapat berakibat kerugian transaksi.

Tabel 3 Perbandingan pendekatan penelitian pengenalan uang kertas

Studi	Objek	Pendekatan	Platform
Fadlurrahman *et al.* (2025)	Rupiah	Pembelajaran mesin seluler	Aplikasi seluler
Kumara *et al.* (2024)	Rupiah	YOLOv8 (deteksi nominal)	Tongkat pintar
Alfatikarani *et al.* (2025)	Rupiah	*Transfer learning* VGG-19	Tidak dinyatakan pada judul

Studi	Objek	Pendekatan	Platform
Khalil *et al.* (2022)	Uang kertas Uni Emirat Arab	Klasifikasi mendalam seluler	Seluler
Penelitian ini	Rupiah	MobileNetV2, *transfer learning*, kelas Bukan_Uang	Seluler (React Native)

Sumber: judul dan metadata publikasi yang dirujuk; protokol evaluasi dan metrik tidak dimasukkan karena tidak sebanding

Protokol evaluasi yang disarankan

Berdasarkan pengalaman ini, sistem pengenal serupa sebaiknya dievaluasi pada tiga lapis. Lapis pertama ialah uji internal untuk memastikan pelatihan berjalan benar. Lapis kedua ialah uji dunia nyata yang dipisahkan sejak awal, memiliki protokol pemotretan terdokumentasi (perangkat, jarak, latar belakang, pencahayaan, dan kondisi uang), serta tidak pernah dipakai untuk melatih atau menyetel model. Lapis ketiga ialah uji ujung ke ujung melalui layanan dan aplikasi yang sebenarnya, agar perbedaan praproses pada jalur penyajian ikut terukur. Penelitian ini hanya melaksanakan lapis pertama dan kedua, sehingga lapis ketiga menjadi pekerjaan lanjutan yang paling mendesak sebelum aplikasi disebarluaskan.

Implikasi dan keterbatasan

Hasil ini mengarahkan pada lima langkah perbaikan. Pertama, kinerja uji dunia nyata dijadikan metrik utama, bukan metrik pendamping. Kedua, data latih diperkaya dengan foto ponsel yang beragam dalam perangkat, latar belakang, pencahayaan, jarak, dan kondisi fisik uang kertas, termasuk emisi lain. Ketiga, sebagian blok akhir *backbone* dilatih lanjut (*fine-tuning*) dengan laju belajar kecil. Keempat, pembagian data dilakukan per kelompok kemiripan atau sesi pemotretan, dan praproses penyajian disamakan dengan pelatihan. Kelima, ambang kepercayaan atau entropi ditambahkan agar aplikasi dapat menjawab bahwa citra belum dapat dikenali, disertai umpan balik suara serta pengujian bersama pengguna disabilitas netra.

Keterbatasan penelitian meliputi satu konfigurasi hiperparameter tanpa pengulangan dengan *seed* berbeda sehingga tidak ada interval kepercayaan, ukuran uji dunia nyata yang kecil (259 foto, 29 sampai 42 per kelas), protokol pengambilan foto dunia nyata yang belum terdokumentasi lengkap, dominasi emisi 2016 pada data latih, pembagian acak tanpa pengelompokan, dan ketiadaan uji pengguna. Karena itu, temuan dibaca sebagai bukti adanya kesenjangan besar yang perlu ditindaklanjuti, bukan sebagai estimasi presisi kinerja aplikasi di lapangan.

KESIMPULAN

Penelitian ini membangun RupiahVision, aplikasi seluler pengenal nominal Rupiah berbasis MobileNetV2 dengan transfer learning, dan mengevaluasi modelnya pada dua tingkat dengan praproses pelatihan. Model mencapai akurasi 92,99% pada uji internal tetapi hanya 48,65% pada foto dunia nyata, dengan kesalahan yang menumpuk pada prediksi Rp2.000 dan Rp20.000, sedangkan kelas Bukan_Uang tetap terdeteksi dengan baik. Kesenjangan ini menunjukkan bahwa akurasi uji internal tidak memadai sebagai dasar klaim kesiapan aplikasi bantu. Penelitian lanjutan disarankan memperkaya data foto ponsel yang beragam, melatih lanjut sebagian *backbone*, menyamakan praproses pelatihan dan penyajian, menambahkan penolakan berbasis ketidakpastian, serta menguji aplikasi bersama pengguna disabilitas netra sebelum diluncurkan secara luas. Karena berasal dari satu konfigurasi dan 259 foto uji, temuan ini bersifat indikatif, dan kinerja ujung ke ujung aplikasi belum diukur.

UCAPAN TERIMA KASIH

Para penulis mengucapkan terima kasih kepada program Pijak in collaboration with IBM SkillsBuild atas beasiswa intensif, bimbingan, dan kesempatan mengerjakan proyek akhir yang menjadi dasar penelitian ini, serta kepada Dicoding Indonesia atas platform dan materi pembelajarannya.

KONTRIBUSI PENULIS

Ahmad Ngiliyun: Conceptualization, Methodology, Formal Analysis, Writing - Original Draft, dan Writing - Review and Editing; M. M. Irfan Subakti: Supervision dan Writing - Review and Editing; Rendi Agus Sucipto: Software, Data Curation, dan Investigation; Nikolas Febrianto: Investigation, Validation, dan Resources; serta Ika Nurfitriani: Data Curation, Visualization, dan Project Administration. Semua penulis telah membaca dan menyetujui versi akhir naskah ini.

PERNYATAAN KETERSEDIAAN DATA

Data penelitian ini tersedia dari para penulis atas permintaan yang wajar.

PERNYATAAN BEBAS KONFLIK KEPENTINGAN

Para penulis menyatakan bahwa tidak ada konflik kepentingan finansial maupun hubungan pribadi yang dapat memengaruhi hasil yang dilaporkan dalam naskah ini.

PERNYATAAN ETIKA PENELITIAN DAN PUBLIKASI

Para penulis menyatakan bahwa penelitian dan penulisan naskah ini telah mematuhi standar etika penelitian dan publikasi serta bebas dari plagiasi.

PERNYATAAN PEMANFAATAN TEKNOLOGI ASISTIF

Para penulis menyatakan bahwa Kecerdasan Buatan Generatif (*Generative Artificial Intelligence*) dan teknologi asistif lainnya tidak digunakan secara berlebihan dalam penelitian dan penulisan naskah ini. Secara khusus, Claude (Anthropic) digunakan untuk menyusun draf naskah dari materi proyek, memeriksa konsistensi angka terhadap keluaran evaluasi, dan membantu pembuatan diagram alur serta *confusion matrix*. Para penulis telah meninjau dan menyunting semua konten yang dihasilkan AI serta bertanggung jawab penuh atas ketepatan naskah akhir.

REFERENSI

Alfatikarani, R., Suciningtyas, L., Bimasakti, G. G., Mardhatillah, F. P., Paragas, J. R., dan Tjahyaningtijas, H. P. A. (2025). Indonesia rupiah currency detection for visually impaired people using transfer learning VGG-19. *SINERGI*, *29*(1), 241-250. https://doi.org/10.22441/sinergi.2025.1.022

anidwiastuti. (n.d.). *Rupiah banknotes dataset* [Data set]. Kaggle. https://www.kaggle.com/datasets/anidwiastuti/rupiah-banknotes-dataset

Bourne, R., Steinmetz, J. D., Flaxman, S., Briant, P. S., Taylor, H. R., Resnikoff, S., Casson, R. J., Abdoli, A., Abu-Gharbieh, E., Afshin, A., Ahmadieh, H., Akalu, Y., Alamneh, A. A., Alemayehu, W., Alfaar, A. S., Alipour, V., Anbesu, E. W., Androudi, S. N., Arabloo, J., ... dan GBD 2019 Blindness and Vision Impairment Collaborators. (2021). Trends in prevalence of blindness and distance and near vision impairment over 30 years: An analysis for the Global Burden of Disease Study. *The Lancet Global Health*, *9*(2), e130-e143. https://doi.org/10.1016/S2214-109X(20)30425-3

Fadlurrahman, H. N., Affandy, A., dan Cahyadi, D. F. (2025). Smart Rupiah recognition: A mobile machine learning approach for visually impaired users. *Scientific Journal of Informatics*, *12*(4), 577-586. https://doi.org/10.15294/sji.v12i4.28930

Khalil, A., Yaghi, M., Basmaji, T., Faizal, M., Farhan, Z., Ali, A., dan Ghazal, M. A. (2022). Mobile deep classification of UAE banknotes for the visually challenged. *2022 International Conference on Future Internet of Things and Cloud (FiCloud)*, 321-325. https://doi.org/10.1109/FiCloud57274.2022.00053

Kostidjan, O. D., Sunaryono, D., Baskoro, F., Sabilla, S. I., Purwananto, Y., dan Subakti, M. M. I. (2026). Boundary-aware multi-stage with Mobile U-Net for hair segmentation in dermoscopic images. *International Journal of Intelligent Engineering and Systems*, *19*(3), 712-730. https://doi.org/10.22266/ijies2026.0331.43

Kumara, I. M. S., Jati, G. P. R. S., dan Yuniari, N. P. W. (2024). Integrate YOLOv8 algorithm for Rupiah denomination detection in all-in-one smart cane for visually impaired. *Techno Com*, *23*(1), 176-186. https://doi.org/10.62411/tc.v23i1.9734

Malik, H. H., Permana, I. S., Muhammad, A. H., dan Kusnawi, K. (2026). Comparison of Bayesian Markov chain Monte Carlo and machine learning algorithms for student cumulative grade point average prediction with feature engineering. *Bulletin of Network Engineer and Informatics*, *4*(1), 377-386. https://doi.org/10.59688/vfk6qw80

Ngiliyun, A. (2026). Predicting Dota 2 match outcomes using machine learning: A single-player case study and a comparison of pre-match and post-match models. *TECHNOVATAR Jurnal Teknologi, Industri, dan Informasi*, *4*(4), 50-60.

Ngiliyun, A., Wahyuni, D., dan Hidayah, N. F. (2026). Development of a scenario-based padel rules learning application for senior high school students. *DEWANTECH Jurnal Teknologi Pendidikan*, *4*(1), 1-13. https://doi.org/10.61434/dewantech.v4i1.406

Panigrahy, A., dan Verma, A. (2025). Tourist experiences: A systematic literature review of computer vision technologies in smart destination visits. *Journal of Tourism Futures*, *11*(2), 187-202. https://doi.org/10.1108/JTF-04-2024-0073

Permana, I. S., Ngiliyun, A., dan Wahyuni, D. (2026). A computational exploration of football player performance at the FIFA World Cup 2022 using StatsBomb event and 360° spatial data. *Indonesian Journal of Physical Education and Sport Science*, *6*(3), 477-490. https://doi.org/10.52188/ijpess.v6i3.2260

Rosmawan, H., Ardiyansyah, A., Azis, M. F., dan Rafsyahid, J. B. (2026). Analisis perbandingan kinerja IndoBERT dan multilingual BERT (mBERT) pada klasifikasi sentimen ulasan fitur Shopee Live di Google Play Store. *TECHNOVATAR Jurnal Teknologi, Industri, dan Informasi*, *4*(2), 10-20. https://doi.org/10.61434/technovatar.v4i2.376

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., dan Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4510-4520. https://doi.org/10.1109/CVPR.2018.00474

Wahyudi, A. R., Sunaryono, D., Subakti, M. M. I., dan Siswantoro, J. (2026). A low-light robustness framework for face verification with enhancement-based recovery. *Array*, *30*, Article 100968. https://doi.org/10.1016/j.array.2026.100968

Yang, J., Zhou, K., Li, Y., dan Liu, Z. (2024). Generalized out-of-distribution detection: A survey. *International Journal of Computer Vision*, *132*(12), 5635-5662. https://doi.org/10.1007/s11263-024-02117-4

Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., dan He, Q. (2021). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, *109*(1), 43-76. https://doi.org/10.1109/JPROC.2020.3004555